



TUGAS AKHIR - SS 145561

**PERAMALAN PERMINTAAN DARAH DI NGANJUK
(STUDI KASUS UNIT DONOR DARAH PMI
KABUPATEN NGANJUK)**

**DEA TRISHNANTI
NRP 1314 030 044**

**Dosen Pembimbing
Dr. Wahyu Wibowo, S.Si., M.Si.**

**DEPARTEMEN STATISTIKA BISNIS
FAKULTAS VOKASI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER**



TUGAS AKHIR - SS 145561

**PERAMALAN PERMINTAAN DARAH DI NGANJUK
(STUDI KASUS UNIT DONOR DARAH PMI
KABUPATEN NGANJUK)**

**DEA TRISHNANTI
NRP 1314 030 044**

**Dosen Pembimbing
Dr. Wahyu Wibowo, S.Si., M.Si.**

**DEPARTEMEN STATISTIKA BISNIS
FAKULTAS VOKASI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**



FINAL PROJECT - SS 145561

**FORECASTING THE BLOOD REQUEST IN
NGANJUK
(STUDY CASE BLOOD DONOR UNIT OF PMI
NGANJUK)**

**DEA TRISHNANTI
NRP 1314 030 044**

**Supervisor
Dr. Wahyu Wibowo, S.Si., M.Si.**

**DEPARTMENT OF BUSINESS STATISTICS
FACULTY VOCATIONAL
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017**

LEMBAR PENGESAHAN

PERAMALAN PERMINTAAN DARAH DI NGANJUK (STUDI KASUS UNIT DONOR DARAH PMI KAB. NGANJUK)

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Ahli Madya pada
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember

Oleh:

DEA TRISHNANTI
NRP. 1314 030 044

SURABAYA, JULI 2017

Menyetujui,
Pembimbing Tugas Akhir


Dr. Wahyu Wibowo, S.Si., M.Si.
NIP. 19740328 199802 1 001

Mengetahui,
Kepala Departemen Statistika Bisnis
Fakultas Vokasi ITS


Dr. Wahyu Wibowo, S.Si., M.Si.
NIP. 19740328 199802 1 001

PERAMALAN PERMINTAAN DARAH DI NGANJUK (STUDI KASUS UNIT DONOR DARAH PMI NGANJUK)

Nama : Dea Trishnanti
NRP : 1314 030 044
Departemen : Statistika Bisnis Fakultas Vokasi
Pembimbing : Dr. Wahyu Wibowo, S.Si., M.Si.

ABSTRAK

Darah sangat penting bagi keberlangsungan kehidupan manusia, darah merupakan transportasi alami di dalam tubuh yang berfungsi mengedarkan O_2 dan CO_2 serta sari sari makanan di dalam tubuh manusia. Pendarahan hebat yang terjadi pada manusia di sebabkan oleh banyak hal, untuk tetap mendapat asupan darah adalah dengan transfusi darah. PMI bertugas untuk menampung dan mendistribusikan darah kepada resipien. Seringkali PMI kabupaten Nganjuk kekurangan persediaan darah tertentu dikarenakan jumlah persediaan darah di penyimpanan lebih sedikit dibandingkan permintaan masyarakat. Seperti yang terjadi di bulan Oktober 2015, permintaan masyarakat terhadap darah O tidak dapat dipenuhi sehingga PMI Nganjuk mengambil persediaan darah dari UDD daerah lain. Darah menurut Karl Landsteiner di golongakan berdasarkan aglutinin dan antigen yang terkandung di dalam nya menjadi 4 golongan yaitu golongan O, A, B dan AB dimana masing-masing golongan sebisa mungkin tidak saling tercampur. Berdasarkan urgenitas kondisi persediaan darah dan pengelompokkan yang tidak membolehkan mendapat transfusi dari golongan darah lain, maka penulis akan meramalkan jumlah permintaan golongan untuk masing-masing darah. Metode peramalan yang akan digunakan yaitu metode ARIMA *Box-Jenkins* dikarenakan *Box Jenkins* sangat baik dalam meramalkan data jangka pendek. Hasil analisis menunjukkan bahwa model terbaik jumlah permintaan golongan darah O, A, B dan AB berturut-turut adalah ARIMA $(0,1,1)(1,0,0)^{12}$, $(0,1,1)(0,1,0)^{12}$, $(2,1,1)$ dan $(0,1,1)$

Kata kunci: ARIMA *Box-Jenkins*, darah, UDD PMI Kabupaten Nganjuk

FORECASTING THE BLOOD REQUEST IN NGANJUK (STUDY CASE BLOOD DONOR UNIT OF PMI NGANJUK)

Nama : Dea Trishnanti
NRP : 1314 030 044
Departemen : Statistika Bisnis Fakultas Vokasi
Pembimbing : Dr. Wahyu Wibowo, S.Si., M.Si.

ABSTRACT

Blood is very important for the survival of human life, blood is a natural transport in the body that serves to circulate the O₂ and CO₂ and juice of food in the human body. Severe bleeding that occurs in humans caused by many things, to keep getting blood intake is by blood transfusions. PMI is tasked to accommodate and distribute blood to recipients. Often the PMI Nganjuk district lacks a certain blood supply because the amount of blood supply in storage is less than the demand of the community. As happened in October 2015, the public demand for blood O could not be fulfilled so that PMI Nganjuk took blood supplies from other regional UDD. The blood according to Karl Landsteiner is based on agglutinin and the antigen contained in it into 4 groups namely group O, A, B and AB where each group as much as possible not mutually mixed. Based on the urgency of blood supply conditions and groupings that do not allow for transfusion from other blood groups, the authors will predict the number of groups requested for each blood. Forecasting method that will be used is Box-Jenkins ARIMA method because Box-Jenkins is very good in predicting short-term data. The results of the analysis showed that the best model number of blood group demand of O, A, B and AB were ARIMA (0,1,1) (1,0,0) 12, (0,1,1) (0,1, 0) 12, (2,1,1) and (0,1,1).

Keywords: ARIMA Box-Jenkins, blood, UDD PMI Kabupaten Nganjuk

KATA PENGANTAR

Puji syukur kehadiran Tuhan Yang Maha Esa yang telah melimpahkan segala rahmat dan hidayah-Nya, sehingga saya dapat menyelesaikan Tugas Akhir ini. Tersusunnya Tugas Akhir ini tidak lepas dari bantuan, arahan, dan petunjuk berbagai pihak. Oleh karena itu, saya penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Wahyu Wibowo, S.Si., M.Si selaku Kepala Departemen Statistika Bisnis ITS sekaligus dosen pembimbing yang bersedia meluangkan waktu dan pemikiran untuk membimbing saya.
2. Ibu Mutiah Salamah, M. Kes dan bu Noviyanti Santoso, S.Si.,M.Si selaku dosen penguji yang selalu memberi dukungan dan masukan untuk memperbaiki laporan tugas akhir.
3. Bapak Dr. Brodjol Sutijo Suprih Ulama, M.Si selaku validator dan dosen pengajar mata kuliah peramalan.
4. Ibu Ir. Sri Pingit Wulandari, M.Si selaku Kepala Program Studi Diploma III Departemen Statistika Bisnis ITS.
5. Segenap dosen Departemen Statistika Bisnis ITS yang telah membantu serta memberikan masukan dalam Tugas Akhir ini.
6. Segenap karyawan Departemen Statistika Bisnis ITS yang telah membantu dalam menyiapkan berbagai kebutuhan administrasi Tugas Akhir ini.
7. Bapak Didik, Ibu Herin beserta staff UDD PMI Nganjuk yang selalu membantu dan memberi kemudahan selama pengerjaan laporan.
8. Teman-teman Mahasiswa Statistika Bisnis ITS, khususnya sahabat-sahabat saya di *Pioneer* 2014 atas kebersamaan, bantuan yang tak terhitung dan dukungannya selama menempuh perkuliahan.
9. Sahabat yang dipertemukan di Sekolah Dasar, Sekolah Menengah Pertama dan Sekolah Menengah Atas dan organisasi yang selalu mengirim doa dan dukungan.
10. Tercinta untuk bapak, ibu dan kakak serta seluruh keluarga atas semua yang telah diusahakan untuk saya.

Serta untuk seluruh pihak yang tidak dapat saya ungkapkan satu-satu. Dengan tersusunnya Tugas Akhir ini, saya berharap semoga dapat memberikan kontribusi pada pihak yang membutuhkan. Saya menyadari bahwa laporan Tugas Akhir ini masih jauh dari kesempurnaan, oleh karena itu saya selaku penulis mengharapkan kritik dan saran yang membangun dari para pembaca.

Surabaya, Juli 2017

Dea Trishnanti

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI	viii
DAFTAR TABEL	xi
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	xv
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	4
1.5 Batasan Masalah	4
BAB II TINJAUAN PUSTAKA	
2.1 Analisis Deret Waktu	5
2.2 Stasioneritas dalam <i>Time Series</i>	7
2.3 Fungsi Autokorelasi	8
2.4 Fungsi Autokorelasi Parsial (PACF).....	9
2.5 Estimasi Parameter.....	9
2.6 Uji Signifikansi Parameter.....	11
2.7 Pemeriksaan Diagnostik (<i>Diagnostic Checking</i>) ...	12
2.8 Pemilihan Model Terbaik.....	14
2.9 Darah.....	16
2.10 PMI	17
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data	19
3.2 Langkah Analisis	20
BAB IV ANALISIS DAN PEMBAHASAN	
4.1 Karakteristik Data Permintaan Darah di PMI Nganjuk.....	23
4.2 Permodelan Permintaan Darah Golongan O	26

4.2.1	Identifikasi Model pada Darah Golongan O	
	Permintaan Darah Golongan O.....	32
4.2.1	Estimasi dan Pengujian Parameter pada	
	Permintaan Darah Golongan O.....	34
4.2.3	Analisis Uji Asumsi Residual pada	
	Permintaan Darah Golongan O.....	35
4.2.4	Pemilihan Model Terbaik pada	
	Permintaan Darah Golongan O.....	37
4.3	Permodelan Permintaan Darah Golongan A.....	39
4.3.1	Identifikasi Model pada Permintaan	
	Darah Golongan A.....	39
4.3.2	Estimasi dan Pengujian Parameter	
	pada Permintaan Darah Golongan A	44
4.3.3	Analisis Uji Asumsi Residual pada	
	Permintaan Darah Golongan A.....	46
4.3.4	Pemilihan Model Terbaik	48
4.4	Pemodelan Permintaan Darah Golongan B	50
4.4.1	Identifikasi Model pada Permintaan	
	Darah Golongan B.....	50
4.4.2	Estimasi dan Pengujian Parameter	
	pada Permintaan Darah Golongan B	53
4.4.3	Estimasi dan Pengujian Parameter	
	pada Permintaan Darah Golongan B	55
4.4.4	Pemilihan Model Terbaik	
	pada Permintaan Golongan Darah B	56
4.5	Pemodelan Permintaan Golongan Darah AB.....	58
4.5.1	Identifikasi Model pada Permintaan	
	Golongan Darah AB	58
4.5.2	Estimasi dan Pengujian Parameter	
	pada Permintaan Darah Golongan AB	62
4.5.3	Analisis Uji Asumsi Residual pada	
	Permintaan Golongan Darah AB	63
4.5.4	Pemilihan Model Terbaik pada	
	Permintaan Golongan Darah AB	64
BAB V	KESIMPULAN DAN SARAN	
5.1	Kesimpulan	67

5.2	Saran	67
DAFTAR PUSTAKA		69
LAMPIRAN		71
BIODATA PENULIS		171

DAFTAR TABEL

	Halaman
Tabel 2.1	Tabel Transformasi <i>Box-Cox</i>8
Tabel 3.1	Struktur Data Penelitian19
Tabel 4.1	Karakteristik Permintaan Masing-Masing Golongan Darah23
Tabel 4.2	Hasil Uji <i>Dickey Fuller</i> Sebelum <i>Differencing</i>29
Tabel 4.3	Hasil Uji <i>Dickey Fuller</i> Setelah <i>Differencing</i>31
Tabel 4.4	Parameter pada Permintaan Darah Golongan O34
Tabel 4.5	Asumsi <i>White Noise</i> pada Permintaan Darah Golongan O35
Tabel 4.6	Asumsi Distribusi Normal pada Permintaan Darah Golongan O37
Tabel 4.7	Pemilihan Model Terbaik Permintaan Golongan Darah O37
Tabel 4.8	Hasil Prediksi pada Permintaan Darah Golongan O Tahun 201738
Tabel 4.9	Hasil Uji <i>Dickey Fuller</i> Sebelum <i>Differencing</i>41
Tabel 4.10	Hasil Uji <i>Dickey Fuller</i> Setelah <i>Differencing</i>43
Tabel 4.11	Hasil Uji <i>Dickey Fuller</i> Setelah <i>Differencing</i> 12.....43
Tabel 4.12	Parameter pada Permintaan Darah Golongan A45
Tabel 4.13	Asumsi <i>White Noise</i> pada Permintaan Darah Golongan A46
Tabel 4.14	Asumsi Distribusi Normal pada Permintaan Darah Golongan A47
Tabel 4.15	Pemilihan Model Terbaik Permintaan Golongan Darah A48

Tabel 4.16	Hasil Prediksi pada Permintaan Darah Golongan A Tahun 2017.....	49
Tabel 4.17	Hasil Uji <i>Dickey Fuller</i> Sebelum <i>Differencing</i>	52
Tabel 4.18	Hasil Uji <i>Dickey Fuller</i> Setelah <i>Differencing</i>	52
Tabel 4.19	Parameter pada Permintaan Darah Golongan B	54
Tabel 4.20	Asumsi <i>White Noise</i> pada Permintaan Darah Golongan B.....	55
Tabel 4.21	Asumsi Distribusi Normal pada Permintaan Darah Golongan B.....	56
Tabel 4.22	Pemilihan Model Terbaik Darah B.....	56
Tabel 4.23	Hasil Prediksi pada Permintaan Darah Golongan B Tahun 2017	57
Tabel 4.24	Hasil Uji <i>Dickey Fuller</i> Sebelum <i>Differencing</i>	60
Tabel 4.25	Hasil Uji <i>Dickey Fuller</i> Setelah <i>Differencing</i>	60
Tabel 4.26	Parameter pada Permintaan Darah Golongan B	62
Tabel 4.27	Asumsi <i>White Noise</i> pada Permintaan Darah Golongan AB.....	63
Tabel 4.28	Asumsi Distribusi Normal pada Permintaan Darah Golongan B.....	64
Tabel 4.29	Pemilihan Model Terbaik Permintaan Golongan Darah A.....	64
Tabel 4.30	Hasil Prediksi pada Permintaan Darah Golongan AB Tahun 2017	65

DAFTAR GAMBAR

	Halaman
Gambar 3.1	Diagram Alir.....22
Gambar 4.1	Box-plot Jumlah Permintaan Golongan Darah O.....24
Gambar 4.2	Box-plot Jumlah Permintaan Golongan Darah A.....25
Gambar 4.3	Box-plot Jumlah Permintaan Golongan Darah B.....25
Gambar 4.4	Box-plot Jumlah Permintaan Golongan Darah AB.....26
Gambar 4.5	Time series plot Jumlah Permintaan Golongan Darah O.....27
Gambar 4.6	Box-Cox Permintaan Golongan Darah O.....28
Gambar 4.7	Plot ACF pada Data Permintaan Darah O.....29
Gambar 4.8	Time Series Plot Setelah Differencing30
Gambar 4.9	(a) Plot ACF, (b) Plot PACF Permintaan Darah O yang Telah Stasioner.....32
Gambar 4.10	(a) Plot ACF, (b) Plot PACF Permintaan Darah O Differencing 1233
Gambar 4.11	Time Series Plot Jumlah Permintaan Golongan Darah A.....39
Gambar 4.12	Box-Cox Permintaan Golongan Darah A.....40
Gambar 4.13	Plot ACF pada Data Permintaan Darah Golongan A.....41
Gambar 4.14	Time Series Plot Setelah Differencing42
Gambar 4.15	(a) Plot ACF dan (b) plot PACF Setelah Differencing Lag 12.....44
Gambar 4.16	Plot Box-Cox pada Permintaan Darah Golongan B.....50
Gambar 4.17	Plot Box-Cox pada Permintaan Darah Golongan B.....50
Gambar 4.18	Plot ACF pada Permintaan Darah Golongan B.....51
Gambar 4.19	(a) Plot ACF dan (b) plot PACF

	Setelah Differencing Lag 1	53
Gambar 4.20	Time Series Plot pada Permintaan Darah Golongan AB	58
Gambar 4.21	Plot Box-Cox pada Permintaan Darah Golongan AB	59
Gambar 4.22	Plot ACF pada Data Permintaan Darah Golongan AB	59
Gambar 4.23	(a) Plot ACF dan (b) plot PACF Setelah <i>Differencing</i> Lag 1	61

DAFTAR LAMPIRAN

	Halaman
Lampiran A	Surat Pernyataan Keaslian Data71
Lampiran B	Surat Keterangan Pengambilan Data Permintaan Darah oleh UDD PMI Kabupaten Nganjuk..... 72
Lampiran C	Data Permintaan Darah (Kantong).....73
Lampiran D	Output Golda O.....76
Lampiran D1	<i>Output Minitab Autocorrelation Function sebelum differencing.....76</i>
Lampiran D2	<i>Output Minitab Autocorrelation Function sesudah differencing77</i>
Lampiran E1	<i>Output Minitab Partial Autocorrelation Function sebelum Differencing79</i>
Lampiran E2	<i>Output Minitab Partial Autocorrelation Function sesudah Differencing80</i>
Lampiran E3	<i>Output Minitab Partial Autocorrelation Function sesudah Differencing 1282</i>
Lampiran E4	<i>Output Minitab Partial Autocorrelation Function sesudah differencing 1283</i>
Lampiran F1	Syntax SAS Pengujian <i>Dickey Fuller</i> sebelum <i>differencing</i>85
Lampiran F2	Syntax SAS Pengujian <i>Dickey Fuller</i> setelah <i>differencing</i>86
Lampiran F3	Syntax SAS Pengujian <i>Dickey Fuller</i> sesudah <i>differencing</i> 12.....87
Lampiran G1	<i>Output SAS Hasil Pengujian Dickey Fuller Sebelum Differencing.....88</i>
Lampiran G2	<i>Output SAS Hasil Pengujian Dickey Fuller Sesudah Differencing88</i>
Lampiran H1	Syntax SAS Pengujian Model ARIMA (2,1,0).....89
Lampiran H2	Syntax SAS Pengujian Model ARIMA (0,1,1).....90

Lampiran H3	Syntax SAS Pengujian Model ARIMA (0,1,1)(1,0,0) ¹²	91
Lampiran H4	Syntax SAS Pengujian Model ARIMA (0,1,1)(0,1,0) ¹²	92
Lampiran I1	<i>Output</i> SAS Pengujian Model ARIMA (2,1,0)	93
Lampiran I2	<i>Output</i> SAS Pengujian Model ARIMA (0,1,1)	94
Lampiran I3	<i>Output</i> SAS Pengujian Model ARIMA (0,1,1)(1,0,0) ¹²	95
Lampiran I4	<i>Output</i> SAS Pengujian Model ARIMA (0,1,1)(0,1,0) ¹²	96
Lampiran J1	Penghitungan Manual rMSE ARIMA (0,1,1)	97
Lampiran J2	Penghitungan Manual sMAPE ARIMA (0,1,1)	97
Lampiran J3	Penghitungan Manual rMSE ARIMA (0,1,1)(1,0,0) ¹²	97
Lampiran J4	Penghitungan Manual sMAPE ARIMA (0,1,1)(1,0,0) ¹²	98
Lampiran K	<i>Output Golda A</i>	99
Lampiran K1	<i>Output Minitab Autocorrelation</i> <i>Function sebelum differencing</i>	100
Lampiran K2	<i>Output Minitab Autocorrelation</i> <i>Function sesudah differencing</i>	100
Lampiran L1	<i>Output Minitab Partial Autocorrelation</i> <i>Function sebelum differencing</i>	102
Lampiran L2	<i>Output Minitab Partial Autocorrelation</i> <i>Function sesudah differencing</i>	103
Lampiran L3	<i>Output Minitab Autocorrelation</i> <i>Function sesudah differencing</i> 12.....	105
Lampiran L4	<i>Output Minitab Partial Autocorrelation</i> <i>Function sesudah differencing</i> 12.....	106
Lampiran M1	Syntax SAS Pengujian Dickey Fuller sebelum <i>differencing</i>	108

Lampiran M2	Syntax SAS Pengujian <i>Dickey Fuller</i> sesudah <i>Differencing</i>	109
Lampiran M3	Syntax SAS Pengujian <i>Dickey Fuller</i> sesudah <i>Differencing</i> 12.....	110
Lampiran N1	<i>Output</i> SAS Hasil Pengujian <i>Dickey Fuller</i> Sebelum <i>Differencing</i>	111
Lampiran N2	<i>Output</i> SAS Hasil Pengujian <i>Dickey Fuller</i> Sebelum <i>Differencing</i> 12.....	111
Lampiran N3	<i>Output</i> SAS Hasil Pengujian <i>Dickey Fuller</i> Sesudah <i>Differencing</i>	122
Lampiran O1	Syntax SAS Pengujian Model ARIMA ([1,3,4],1,0)	114
Lampiran O2	Syntax SAS Pengujian Model ARIMA (0,1,1)(0,1,0) ¹²	114
Lampiran O3	Syntax SAS Pengujian Model ARIMA (3,1,0)(0,1,0) ¹²	116
Lampiran O4	Syntax SAS Pengujian Model ARIMA (4,1,0)(0,1,0) ¹²	117
Lampiran O5	Syntax SAS Pengujian Model ARIMA ([1,3,4],1,0)(0,1,0) ¹²	118
Lampiran P1	<i>Output</i> SAS Pengujian Model ARIMA([1,3,4],1,0)	119
Lampiran P2	<i>Output</i> SAS Pengujian Model ARIMA (0,1,1)(0,1,0) ¹²	120
Lampiran P3	<i>Output</i> SAS Pengujian Model ARIMA (1,1,0)(0,1,0) ¹²	121
Lampiran P4	<i>Output</i> SAS Pengujian Model ARIMA (3,1,0)(0,1,0) ¹²	122
Lampiran P5	<i>Output</i> SAS Pengujian Model ARIMA (3,1,0)(0,1,0) ¹²	123
Lampiran P6	<i>Output</i> SAS Pengujian Model ARIMA ([1,3,4],1,0)(0,1,0) ¹²	124
Lampiran Q1	Penghitungan Manual rMSE ARIMA ([1,3,4],1,0)	125
Lampiran Q2	Penghitungan Manual sMAPE ARIMA ([1,3,4],1,0)	125

Lampiran Q3	Penghitungan Manual rMSE ARIMA (0,1,1)(0,1,0) ¹²	126
Lampiran Q4	Penghitungan Manual sMAPE ARIMA (0,1,1)(0,1,0) ¹²	126
Lampiran Q5	Penghitungan Manual rMSE ARIMA (1,1,0)(0,1,0) ¹²	127
Lampiran Q6	Penghitungan Manual sMAPE ARIMA (1,1,0)(0,1,0) ¹²	127
Lampiran Q7	Penghitungan Manual rMSE ARIMA ([1,3,4],1,0)(0,1,0) ¹²	128
Lampiran Q8	Penghitungan Manual rMAPE ARIMA ([1,3,4],1,0)(0,1,0) ¹²	128
Lampiran R	Output Golda B	129
Lampiran R1	<i>Output Minitab Autocorrelation</i> <i>Function sebelum differencing</i>	129
Lampiran R2	<i>Output Minitab Autocorrelation</i> <i>Function sesudah differencing</i>	130
Lampiran S1	<i>Output Minitab Partial Autocorrelation</i> <i>Function sebelum differencing</i>	132
Lampiran S2	<i>Output Minitab Partial Autocorrelation</i> <i>Function sesudah differencing</i>	133
Lampiran S3	<i>Output Minitab Partial Autocorrelation</i> <i>Function sesudah differencing</i> 12.....	135
Lampiran S4	<i>Output Minitab Partial Autocorrelation</i> <i>Function sesudah differencing</i> 12.....	136
Lampiran T1	Syntax SAS Pengujian <i>Dickey Fuller</i> sebelum <i>differencing</i>	138
Lampiran T2	Syntax SAS Pengujian <i>Dickey Fuller</i> sesudah <i>differencing</i>	139
Lampiran T3	Syntax SAS Pengujian <i>Dickey Fuller</i> sesudah <i>differencing</i> 12.....	140
Lampiran U1	<i>Output SAS Hasil Pengujian Dickey</i> <i>Fuller Sebelum Differencing</i>	141
Lampiran U2	<i>Output SAS Hasil Pengujian Dickey</i> <i>Fuller Sesudah Differencing</i>	141

Lampiran V1	Syntax SAS Pengujian Model ARIMA (0,1,1).....	142
Lampiran V2	Syntax SAS Pengujian Model ARIMA (1,1,0).....	143
Lampiran V3	Syntax SAS Pengujian Model ARIMA (1,1,1).....	144
Lampiran V4	Syntax SAS Pengujian Model ARIMA (2,1,0).....	145
Lampiran V5	Syntax SAS Pengujian Model ARIMA (2,1,1).....	146
Lampiran W1	<i>Output</i> SAS Pengujian Model ARIMA (0,1,1).....	147
Lampiran W2	<i>Output</i> SAS Pengujian Model ARIMA (1,1,0).....	148
Lampiran W3	<i>Output</i> SAS Pengujian Model ARIMA (1,1,1).....	149
Lampiran W4	<i>Output</i> SAS Pengujian Model ARIMA (2,1,0).....	150
Lampiran W5	<i>Output</i> SAS Pengujian Model ARIMA (2,1,1).....	151
Lampiran X1	Penghitungan Manual rMSE ARIMA (1,1,1).....	152
Lampiran X2	Penghitungan Manual sMAPE ARIMA (1,1,1).....	152
Lampiran X3	Penghitungan Manual rMSE ARIMA (2,1,1).....	153
Lampiran X4	Penghitungan Manual rMSE ARIMA (2,1,1).....	153
Lampiran Y	<i>Output Golda AB</i>	154
Lampiran Y1	<i>Output Minitab Autocorrelation</i> <i>Function sebelum differencing</i>	154
Lampiran Y2	<i>Output Minitab Autocorrelation</i> <i>Function sesudah differencing</i>	155
Lampiran Z1	<i>Output Minitab Partial Autocorrelation</i> <i>Function sebelum differencing</i>	157

Lampiran Z2	<i>Output Minitab Partial Autocorrelation Function sesudah differencing</i>	158
Lampiran AA1	Syntax SAS Pengujian <i>Dickey Fuller</i> sebelum <i>differencing</i>	160
Lampiran AA2	Syntax SAS Pengujian <i>Dickey Fuller</i> sesudah <i>differencing</i>	161
Lampiran AB1	<i>Output</i> SAS Hasil Pengujian <i>Dickey Fuller</i> Sebelum <i>Differencing</i>	162
Lampiran AB2	<i>Output</i> SAS Hasil Pengujian <i>Dickey Fuller</i> Sesudah <i>Differencing</i>	162
Lampiran AC1	Syntax SAS Pengujian Model ARIMA (0,1,1)	163
Lampiran AC2	Syntax SAS Pengujian Model ARIMA (3,1,0)	164
Lampiran AD1	<i>Output</i> SAS Pengujian Model ARIMA (0,1,1)	165
Lampiran AD2	<i>Output</i> SAS Pengujian Model ARIMA (3,1,0)	166
Lampiran AA	Penghitungan Manual rMSE dan sMAPE	167
Lampiran AE1	Penghitungan Manual rMSE ARIMA (0,1,1)	167
Lampiran AE2	Penghitungan Manual sMAPE ARIMA (0,1,1)	167
Lampiran AE3	Penghitungan Manual rMSE ARIMA (3,1,0)	167
Lampiran AE4	Penghitungan Manual sMAPE (3,1,0)	168
Lampiran AF1	Nilai Peramalan Golongan Darah O	168
Lampiran AF2	Nilai Peramalan Golongan Darah A	169
Lampiran AF3	Nilai Peramalan Golongan Darah B	169
Lampiran AF4	Nilai Peramalan Golongan Darah AB	169

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tubuh manusia memiliki sekitar 4-6 liter darah yang terus mengalir melalui pembuluh darah ke seluruh tubuh. Darah manusia terdiri dari sel-sel darah (sel darah merah, sel darah putih dan trombosit) dalam cairan yang disebut plasma. Ketiga jenis sel darah memiliki peranan khusus dalam tubuh. Sel darah merah atau eritrosit untuk membawa oksigen ke seluruh tubuh dan membawa karbon dioksida, sel darah putih atau leukosit menjadi sistem kekebalan tubuh serta trombosit untuk membantu pembekuan darah. Menurut Karl Landsteiner, golongan darah manusia dikelompokkan menjadi 4 yaitu golongan darah O, golongan darah A, golongan darah B dan golongan darah AB. Golongan darah sistem ABO ini dibedakan hanya oleh sel darah merahnya saja. Sel-sel darah lain tidak memengaruhi penggolongan ABO. Suatu golongan darah adalah pengklasifikasian darah berdasarkan kehadiran atau ketidakhadiran dari substansi antigen yang menempel pada permukaan sel darah merah. (*Blood Typing, Nobelprize*).

Kehilangan darah dari dalam tubuh bisa dikarenakan berbagai hal, seperti kecelakaan dengan perdarahan hebat, menjalani operasi besar, ibu yang pendarahan hebat pada saat melahirkan, dan banyak hal lainnya. Kehilangan banyak darah menyebabkan organ-organ akan kekurangan nutrisi dan oksigen. Akibatnya, dalam waktu singkat terjadi kerusakan jaringan dan kegagalan fungsi organ yang berujung pada kematian. Untuk mencegah hal itu, dibutuhkan pasokan darah yang diperoleh dari unit transfusi darah. Golongan darah sangat penting untuk transfusi darah. Seseorang yang menerima darah (transfusi darah) dari kelompok ABO yang tidak sesuai, bisa berakibat fatal dan mengancam nyawa. Golongan darah O dikenal sebagai donor universal karena dapat memberikan darahnya ke golongan lain. Ini disebabkan golongan darah O yang tidak memiliki antigen

pada permukaan darah merahnya (eritrosit)(mediskus.com, 2017) Kendati begitu, golongan darah O tetap memiliki antibodi terhadap antigen A dan B. Hal inilah yang masih menyisakan risiko terjadinya kehancuran sel darah merah (lisis), saat dilakukan tranfusi. Maka tidak ada yang dikatakan donor universal. Sedapat mungkin lakukan tranfusi dengan golongan darah yang sesuai. Bila keadaan sangat mendesak barulah dilakukan transfusi dari golongan darah O ke golongan darah lain (kompas.com, 2016).

Untuk menghindari kekurangan persediaan darah, PMI Nganjuk melakukan banyak cara untuk menggalang darah. Cara menggalang darah yaitu dengan mengambil darah dari pendonor rutin dan pendonor keliling, hal ini ternyata belum mampu memenuhi permintaan. Kondisi saat menipisnya persediaan darah di PMI Nganjuk pun terjadi disebabkan bukan karena sedikitnya pendonor tetapi meningkatnya jumlah permintaan (kebutuhan) darah, menurut PMI Nganjuk hal tersebut sering terjadi terutama ketika hari libur nasional seperti hari raya idul fitri. Bulan puasa banyak masyarakat tidak mau mendonor sedangkan pada hari raya idul fitri banyak terjadi kecelakaan pemudik. Menurut laporan bulanan Oktober 2016 kebutuhan darah sebanyak 1.186 kantong sedangkan jumlah kebutuhan yang dapat dipenuhi 1.079 kantong sehingga untuk memenuhi permintaan, UDD PMI Nganjuk harus mengambil persediaan dari UDD PMI Madiun sebanyak 150 kantong.

Kondisi bulan Oktober 2015, kebutuhan darah O sebanyak 346 kantong sedangkan yang tersedia sebanyak 112 kantong, kebutuhan darah A sebanyak 194 sedangkan yang tersedia 47 kantong, begitu juga kebutuhan darah B sebanyak 312 kantong sedangkan yang tersedia 57 kantong. Kekurangan stok juga terjadi pada permintaan darah AB sebanyak 68 kantong sedangkan donor darah AB sebanyak 16 kantong. Pada bulan berikutnya yaitu Nopember 2015, kekurangan persediaan darah terjadi pada golongan darah B dan AB hal ini dikarenakan

permintaan darah yg tinggi tetapi tidak diiringi dengan pemasukan donor darah.

Permintaan darah merupakan hal yang tidak terduga seperti halnya kecelakaan atau sakit yang tidak terduga, maka persediaan darah di rumah sakit dan PMI harus selalu ada agar mampu memenuhi kebutuhan resipien yang mendadak. UDD PMI Nganjuk perlu meramalkan permintan darah di Nganjuk golongan darah O, A, B dan AB untuk mempersiapkan permintaan darah di masa mendatang sehingga dapat mengurangi kemungkinan kekurangan persediaan dan tidak bergantung pada persediaan darah UDD PMI daerah lain.

Maka dari itu kali ini, dilakukan peramalan permintaan darah di Nganjuk dengan memanfaatkan metode *ARIMA Box-Jenkins*.

1.2 Rumusan Masalah

PMI memiliki pendonor rutin untuk setiap golongan darah tetapi hal ini tidak menjamin stok persediaan darah dapat memenuhi permintaan resipien yang mendadak sehingga kekurangan persediaan darah sering dipenuhi oleh UDD daerah lain. Sedangkan transfusi darah lebih baik sesuai dengan golongan darah resipien untuk menghindari kegagalan peleburan darah, maka perlu didapatkan model peramalan permintaan darah per golongan darah dan hasil peramalan permintaan darah untuk bulan Januari 2017 – Desember 2017.

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai yakni untuk mengetahui model peramalan terbaik untuk jumlah permintaan darah berdasar golongan di UDD PMI Kota Nganjuk serta hasil peramalannya untuk bulan Januari 2017 – Desember 2017.

1.4 Manfaat Penelitian

Manfaat dari hasil penelitian ini yakni sebagai informasi bagi UDD PMI Kota Nganjuk dalam mengambil kebijakan guna pemenuhan kebutuhan darah di Nganjuk agar tidak kekurangan persediaan darah. Kebijakan yang dimaksud adalah menambah persediaan darah dari UDD daerah lain atau mengatur kembali strategi penggalangan darah di Kota Nganjuk.

1.5 Batasan Masalah

Penelitian hanya dilakukan di Nganjuk tepatnya di Unit Donor Darah (UDD) PMI Kota Nganjuk. Data yang digunakan yakni data permintaan jenis darah menurut golongan darah di Nganjuk pada tahun 2013 hingga tahun 2016. Banyak observasi yaitu 48. Distribusi darah berdasarkan RSUD Nganjuk, RSUD Kertosono, RSIA Nganjuk, RS Bhayangkara dan klinik di wilayah kabupaten Nganjuk. Persediaan darah yang dimaksud adalah darah yang layak untuk di gunakan pada bulan itu juga.

BAB II TINJAUAN PUSTAKA

2.1 Analisis Deret Waktu

Analisis deret waktu atau *time series analysis* adalah rangkaian pengamatan yang tersusun berdasarkan urutan waktu (Wei, 2006). Setiap pengamatan dinyatakan sebagai variabel random Z_t yang diperoleh berdasarkan urutan waktu pengamatan tertentu (t_i). Adapun model-model *time series* diantaranya:

1. Model *Autoregressive* (AR)

Model *autoregressive* (AR) merupakan model yang menggambarkan situasi dimana pengamatan pada waktu ke- t berhubungan linear dengan pengamatan pada waktu sebelumnya. Bentuk fungsi persamaan untuk model pada *autoregressive* (AR) pada orde p adalah sebagai berikut

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.1)$$

atau juga dapat disederhanakan menjadi persamaan berikut.

$$\phi_p(B) \dot{Z}_t = a_t \quad (2.2)$$

dimana :

$$\dot{Z}_t = Z_t - \mu$$

$$\phi_p = \text{parameter } autoregressive \text{ ke-} p$$

$$a_t = \text{nilai kesalahan pada waktu ke-} t$$

$$\mu = \text{suatu konstanta rata-rata}$$

2. Model *Moving Average* (MA)

Model *moving average* atau proses rata-rata bergerak dari orde ke- q yang persamaannya dapat ditulis pada persamaan

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.3)$$

atau juga bisa disederhanakan kedalam persamaan

$$\dot{Z}_t = \theta_q(B) a_t \quad (2.4)$$

dimana :

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$$\dot{Z}_t = Z_t - \mu$$

$$\theta_q = \text{parameter } moving \text{ average ke-} q$$

$$a_t = \text{nilai kesalahan pada waktu ke-} t$$

3. Model *Autoregressive Moving Average* (ARMA)

Model *autoregressive moving average* (ARMA) merupakan model campuran atau gabungan antara model AR (p) dan MA (q). Bentuk fungsi persamaan untuk model *autoregressive moving average* (ARMA) adalah sebagai berikut.

$$\phi_p(B)\dot{Z}_t = \theta_q(B)a_t \quad (2.5)$$

dimana :

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (2.6)$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (2.7)$$

4. Model *Autoregressive Intergrated Moving Average* (ARIMA)

Model ARIMA adalah model peramalan yang termasuk dalam kelompok linier. Model ARIMA dapat digunakan pada data yang memiliki pola non musiman ataupun musiman. Model data yang memiliki pola non musiman dengan *differencing* orde d yang dapat dinotasikan sebagai ARIMA (p, d, q). Secara matematis model ARIMA (p, d, q) dapat ditulis sebagai berikut (Wei, 2006).

$$\phi_p(B)^p (1 - B)^d \dot{Z}_t = \theta_q(B)^q a_t \quad (2.8)$$

Model ARIMA musiman merupakan model yang membentuk pola musiman dan bentuk modelnya sesuai dengan persamaan berikut ini.

$$\Phi_p(B^s)(1 - B^s)^D \dot{Z}_t = \Theta_Q(B^S)a_t \quad (2.9)$$

Model ARIMA musiman multiplikatif dinotasikan dengan ARIMA (p, d, q) (P, D, Q)^s yang mempunyai faktor non musiman dan musiman pengamatan waktu ke- t . Bentuk fungsi persamaan model ARIMA multiplikatif adalah sebagai berikut.

$$\Phi_p(B^S)\phi_p(1 - B)^d(1 - B^S)\dot{Z}_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (2.10)$$

dimana :

$$\dot{Z}_t = Z_t - \mu$$

$$B = \text{operator back shift}$$

$$\Phi_p = \text{orde } P \text{ pada koefisien komponen AR musiman}$$

Θ_Q = orde Q pada koefisien komponen MA musiman

(Wei, 2006)

2.2 Stasioneritas dalam *Time Series*

Stasioneritas data time series merupakan suatu keadaan dimana proses pembangkitan yang mendasari suatu deret berkala didasarkan pada nilai mean (rata-rata) dan nilai varians yang konstan (Makridakis dkk, 1999). Suatu data dikatakan tidak stasioner bisa disebabkan oleh *mean* (rata-rata) tidak konstan atau varian dari data tidak konstan. Kestasioneran data dalam *mean* dapat dilihat dengan plot ACF, selain itu salah satu pengujian yang dipakai untuk mengetahui stasioneritas data dalam *mean* yaitu menggunakan pengujian *Augmented Dickey Fuller* (ADF) dengan hipotesis dan statistik uji sebagai berikut (Gujarati, 2012).
Hipotesis :

$H_0 : \delta = 0$ (Terdapat akar unit, variabel Z_t tidak stasioner)

$H_1 : \delta \neq 0$ (Tidak terdapat akar unit, variabel Z_t stasioner)

Statistik uji :

$$t = \frac{\hat{\delta}}{Se(\hat{\delta})} \quad (2.11)$$

dimana :

$$Standard\ error\ (Se) = \sqrt{\frac{\hat{\sigma}^2}{n-1}}$$

$$\hat{\sigma}^2 = \sum_{t=1}^n (Z_t - \delta Z_{t-1})^2$$

n = banyaknya observasi

Z_t = nilai aktual pada waktu ke- t

Daerah penolakan, H_0 di tolak jika $|t_{hitung}| > t_{\alpha/2; n-1}$, dimana n adalah banyaknya observasi. Suatu data yang tidak stasioner dalam *mean* dapat diatasi dengan melakukan *differencing* (Markidakis, Wheelwright, & McGEE, 1999).

$$Y_t = Z_t - Z_{t-1}$$

dengan Z_t merupakan nilai setelah dilakukan *differencing*, sedangkan untuk mengatasi data yang tidak stasioner dalam *varians* dapat dilakukan dengan transformasi. Transformasi yang umum digunakan adalah transformasi *Box-Cox* dalam persamaan berikut ini (Wei, 2006).

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.12)$$

dengan λ adalah parameter transformasi. Nilai pendugaan parameter λ dapat dicari dengan menggunakan metode kemungkinan *Maksimum Likelihood Estimation* (Draper, 1992).

Nilai λ yang dipilih adalah nilai λ yang meminimumkan jumlah kuadrat residual sehingga memiliki *varians* yang minimum (Wei, 2006). Berikut merupakan nilai estimasi dari λ

Tabel 2.1 Tabel Transformasi *Box-Cox*

Nilai Estimasi	Transformasi
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t

(Wei, 2006)

2.3 Fungsi Autokorelasi (ACF)

Fungsi autokorelasi atau sering disebut sebagai *Autocorrelation Function* (ACF) merupakan suatu hubungan linier antara pengamatan Z_t dengan pengamatan Z_{t-k} pada data *time series* yang dipisahkan oleh waktu ke- k (Wei, 2006). Fungsi autokorelasi ini juga dapat digunakan untuk melihat kestasioneran data dalam mean serta mengidentifikasi model data *time series* tersebut. Fungsi autokorelasi terlihat pada persamaan halaman berikutnya.

$$\hat{\rho}_k = \frac{\gamma_k}{\gamma_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.13)$$

dimana

k = lag ke- k

n = banyak observasi

Z_t = nilai aktual pada waktu ke- t

$$\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t$$

(Wei, 2006)

2.4 Fungsi Autokorelasi Parsial (PACF)

Autokorelasi Parsial digunakan untuk mengukur tingkat keeratan hubungan antara pasangan data Z_t dengan Z_{t+k} setelah pengaruh variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ dihilangkan (Wei, 2006).

Perhitungan nilai PACF sampel lag ke- k dimulai dari menghitung $\hat{\phi}_{11} = \hat{\rho}_1$, sedangkan fungsi autokorelasi parsial untuk sampel sebagai berikut.

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{k,j} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{k,j} \hat{\rho}_j} \quad (2.14)$$

dengan $\hat{\phi}_{k+1,j} = \hat{\phi}_{k,j} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}$ untuk $j = 1, 2, \dots, k$

dimana :

$\hat{\rho}_k$ = nilai autokorelasi lag ke- k

$\hat{\phi}_{k+1,j}$ = nilai parsial autokorelasi lag ke- k

sehingga

$$\hat{\phi}_{k,k} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \hat{\rho}_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \hat{\rho}_j} \quad (2.15)$$

(Wei, 2006)

2.5 Estimasi Parameter

Setelah diperoleh model dugaan awal ARIMA (p,d,q) , langkah selanjutnya yaitu dilakukan estimasi parameter. Estimasi parameter pada model ARIMA yang paling umum digunakan adalah metode *Conditional Least Square* (CLS).

Metode *Conditional Least Square* (CLS) bekerja dengan cara mencari nilai parameter yang meminimumkan jumlah kuadrat *error* atau *Sum Square Error* (SSE) (Cryer & Chan, 2008). Misalkan untuk AR(1), maka model regresi dengan variabel prediktor Z_{t-1} dan variabel respon Z_t yang dinyatakan sebagai berikut (Cryer & Chan, 2008).

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + a_t \quad (2.16)$$

dimana:

a_t = nilai kesalahan pada saat t

Z_t = nilai aktual pada waktu ke t

μ = suatu konstanta

Dengan nilai SSE adalah sebagai berikut.

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (2.17)$$

Kemudian diturunkan terhadap μ dan ϕ dan disamakan dengan nol sehingga diperoleh nilai taksiran parameter untuk seperti pada persamaan 2.18

$$\mu = \frac{1}{(n-1)(1-\phi)} = \left[\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1} \right] \quad (2.18)$$

Dan nilai taksiran parameter ϕ didapatkan seperti persamaan

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.19)$$

Setelah diperoleh estimasi parameter model, kemudian dilakukan pengujian signifikansi parameter. (Cryer & Chan, 2008)

2.6 Uji Signifikansi Parameter

Pengujian signifikansi parameter model ARIMA dilakukan untuk mengetahui parameter model signifikan atau tidak. Selain itu pengujian ini juga digunakan untuk menguji apakah suatu parameter model ARIMA layak masuk ke dalam suatu model. Hipotesis yang digunakan seperti yang dituliskan berikut ini.

Hipotesis :

$H_0 : \hat{\beta} = 0$ (parameter tidak signifikan)

$H_1 : \hat{\beta} \neq 0$ (parameter signifikan)

dimana $\hat{\beta}$ adalah parameter-parameter pada model ARIMA

Taraf signifikan : $\alpha = 0,05$

Statistik uji:

$$t_{hitung} = \frac{\hat{\beta}}{Se(\hat{\beta})} \quad (2.20)$$

dimana :

$$SE(\hat{\beta}) = \sqrt{\hat{\sigma}_a^2 \left(\sum_{t=2}^n Z_{t-1}^2 \right)^{-1}}$$

$$\hat{\sigma}_a^2 = \frac{\sum_{t=2}^n (Z_t - \hat{\beta} Z_{t-1})^2}{(n-1)}$$

$SE(\hat{\beta})$ = standar error dari nilai taksiran β

n = banyaknya observasi

m = banyak parameter yang ditaksir

Z_t = nilai aktual pada waktu ke- t

Daerah penolakan, H_0 di tolak jika $|t_{hitung}| > t_{\alpha/2, n-m}$, dimana n adalah banyaknya observasi dan m adalah jumlah parameter yang ditaksir.

2.7 Pemeriksaan Diagnostik (*Diagnostik Checking*)

Dua asumsi dasar yang harus dipenuhi dalam pengujian kesesuaian model yaitu residual model *White Noise* dan berdistribusi normal.

a. Pengujian Residual *White Noise*

Residual bersifat *white noise* jika tidak terdapat korelasi antar residual. Plot residual dapat digunakan untuk melihat apakah varians residual konstan, sedangkan untuk melihat residual bersifat *white noise* dapat dilakukan dengan melihat plot sampel ACF residualnya (Wei, 2006). Pengujian untuk melihat residual telah *white noise* dengan menggunakan hipotesis dan statistik uji *Ljung-Box* sebagai berikut.

Hipotesis:

$$H_0 : \rho_{a_{t1}} = \rho_{a_{t2}} = \rho_{a_{t3}} = \dots = \rho_{a_{tk}} = 0 (\text{residual white noise})$$

$$H_1 : \text{minimal ada satu } \rho_{a_{tk}} \neq 0 \text{ untuk } k = 1, 2, \dots, K$$

Statistik Uji:

$$(2.22)$$

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_{a_k}^2$$

dimana :

$\hat{\rho}_{a_k}$ = taksiran autokorelasi residual lag ke- k

n = banyaknya residual

K = lag maksimum

Daerah penolakan yaitu H_0 di tolak jika Q lebih besar dari $\chi^2_{(K-p-q)}$, atau P -value kurang dari α sebesar 0,05, dimana p dan q adalah orde dari model ARIMA (p, q). (Wei, 2006)

b. Pengujian Residual Berdistribusi Normal

Asumsi yang harus dipenuhi adalah residual berdistribusi normal. Pengujian residual berdistribusi normal dilakukan dengan menggunakan uji *Kolmogorov Smirnov*. Berikut adalah perumusan hipotesis dengan menggunakan statistik uji *Kolmogorov Smirnov* (Daniel, 1989).

Hipotesis :

$H_0 : F_n(a_t) = F_0(a_t)$ (Residual berdistribusi normal)

$H_1 : F_n(a_t) \neq F_0(a_t)$ (Residual tidak berdistribusi normal)

Statistik uji :

$$D = \text{Sup}_{a_t} |F_n(a_t) - F_0(a_t)| \quad (2.23)$$

dimana :

$F_n(a_t)$ = nilai peluang kumulatif distribusi yang belum diketahui

$F_0(a_t)$ = nilai peluang kumulatif dari distribusi normal

$S(a_t)$ = fungsi peluang kumulatif yang dihitung dari data sampel

$\text{Sup}(a_t)$ = nilai supremum atau nilai maksimum dari $|S(a_t) - F_0(a_t)|$

Daerah penolakan, H_0 di Tolak, jika nilai D lebih besar dari $D_{1-\alpha, n}$, dimana n sebagai derajat bebasnya. (Daniel, 1989)

2.8 Pemilihan Model Terbaik

Pada analisis *time series*, terdapat kemungkinan bahwa terdapat lebih dari satu model yang parameternya signifikan dan memenuhi asumsi residual *white noise* dan berdistribusi normal, sehingga diperlukan suatu kriteria tertentu untuk dapat menentukan model yang akan digunakan. Terdapat beberapa kriteria pemilihan model yang dapat digunakan antara lain AIC (*Akaike's Information Criterion*) dan SBC (*Schwartz's Bayesian Criterion*) untuk data *in sample* serta sMAPE (*symmetric Mean Absolute Percentage Error*) dan RMSE (*Root Mean Square Error*) untuk data *out sample* (Wei, 2006). Pemilihan model terbaik dilakukan melalui pendekatan *in sample* dan *out sample*, model terbaik dipilih berdasarkan kesalahan dalam peramalan (*forecast error*). Kriteria tersebut adalah :

a. Pendekatan *In Sample*

AIC adalah suatu kriteria pemilihan model terbaik dengan mempertimbangkan banyaknya parameter dalam model. Pada kriteria AIC diasumsikan suatu model statistik dengan M parameter sebagai penduga dari data. AIC digunakan untuk model yang memiliki parameter tidak terlalu banyak, sehingga jika parameter dalam model terlalu banyak akan menjadi bias. Model ini diperkenalkan oleh Akaike yaitu sebagai berikut:

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2.23)$$

dimana

M : merupakan banyaknya parameter dalam model

$\hat{\sigma}_a^2$: merupakan varians residual

n : menyatakan banyaknya residual

\ln : natural log

Sedangkan untuk kriteria Bayesian dalam pemilihan model terbaik yang disebut dengan SBC dengan persamaan seperti berikut ini.

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \quad (2.24)$$

dimana :

M : merupakan banyaknya parameter dalam model

$\hat{\sigma}_a^2$: merupakan varians residual

n : banyaknya observasi

\ln : *natural log*

b. Pendekatan *Out Sample*

Perhitungan akurasi untuk data *out sample* dengan menggunakan kriteria *RMSE* dan *sMAPE*. *RMSE* merupakan kriteria pemilihan model terbaik berdasarkan pada hasil sisa ramalannya digunakan untuk segala satuan data. *RMSE* digunakan dengan tujuan supaya satuan pengukuran data tidak berubah, dapat dihitung dengan rumus sebagai berikut (Gooijer & Hyndman, 2006).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (2.25)$$

dimana :

n : banyaknya observasi

Z_t : nilai aktual pada waktu ke- t

\hat{Z}_t : nilai ramalan pada waktu ke- t

Sedangkan *Symmetric Mean Absolute Percentage Error* (*sMAPE*) digunakan untuk mengetahui rata-rata harga mutlak dari persentase kesalahan tiap model. *sMAPE* digunakan untuk data yang mempunyai nilai besar dan dapat menghindari permasalahan *error* yang besar ketika nilai aktualnya melebihi nilai ramalannya atau sebaliknya. Rumus *sMAPE* dapat dituliskan seperti berikut ini (Gooijer & Hyndman, 2006).

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{\frac{1}{2}(Z_t + \hat{Z}_t)} \times 100\% \quad (2.26)$$

dimana :

n : banyaknya observasi

Z_t : nilai aktual pada waktu ke- t

\hat{Z}_t : nilai ramalan pada waktu ke- t

(Gooijer & Hyndman, 2006)

2.9 Darah

Darah adalah jaringan cair yang terdiri atas dua bagian yaitu plasma darah dan sel darah. Sel darah terdiri dari tiga jenis yaitu: butir pembeku (trombosit), sel darah putih (leukosit), dan sel darah merah atau eritrosit (Evelyn C. Pearce, 2006). Darah berfungsi sebagai alat pengangkut yaitu mengambil oksigen dari paru-paru untuk diedarkan ke seluruh jaringan tubuh, mengangkut karbondioksida dari jaringan untuk dikeluarkan melalui paru-paru dibagikan ke seluruh jaringan tubuh, mengeluarkan zat-zat yang tidak berguna bagi tubuh untuk dikeluarkan melalui kulit dan ginjal, sebagai pertahanan tubuh terhadap serangan penyakit, menyebarkan panas keseluruh tubuh.

Pada tubuh orang dewasa sehat, dalam setiap milimeter kubik darah terhadap $\pm 5.000.000$ sel darah merah. Strukturnya terdiri dari pembungkus luar (stroma) berisi masa hemoglobin. Bila terjadi pendarahan, sel darah merah dengan hemoglobin-nya sebagai pembawa hemoglobin akan hilang. Pada pendarahan sedang, sel-sel itu diganti dalam waktu beberapa minggu saja. Tetapi bila kadar hemoglobin turun sampai 40% atau dibawahnya, diperlukan transfusi darah (Evelyn C. Pearce, 2006). Golongan darah adalah ciri khusus darah dari suatu individu karena adanya perbedaan jenis karbohidrat dan protein pada permukaan membran sel darah merah. Golongan darah manusia ditentukan berdasarkan jenis antigen dan antibodi yang terkandung dalam darahnya, sebagai berikut:

1. Individu dengan golongan darah A memiliki sel darah merah dengan antigen A di permukaan membran selnya dan menghasilkan antibodi terhadap antigen B dalam serum darahnya. Sehingga, orang dengan golongan darah A hanya dapat menerima darah dari orang dengan golongan darah A atau O.
2. Individu dengan golongan darah B memiliki antigen B pada permukaan sel darah merahnya dan menghasilkan antibodi terhadap antigen A dalam serum darahnya. Sehingga, orang

dengan golongan darah B hanya dapat menerima darah dari orang dengan golongan darah B atau O

3. Individu dengan golongan darah AB memiliki sel darah merah dengan antigen A dan B serta tidak menghasilkan antibodi terhadap antigen A maupun B. Sehingga, orang dengan golongan darah AB dapat menerima darah dari orang dengan golongan darah ABO apapun dan disebut resipien universal. Namun, orang dengan golongan darah AB tidak dapat mendonorkan darah kecuali pada sesama AB.

4. Individu dengan golongan darah O memiliki sel darah tanpa antigen, tapi memproduksi antibodi terhadap antigen A dan B. Sehingga, orang dengan golongan darah O dapat mendonorkan darahnya kepada orang dengan golongan darah ABO apapun dan disebut donor universal. Namun, orang dengan golongan darah O hanya dapat menerima darah dari sesama O.

2.10 PMI

Unit Transfusi Darah Palang Merah Indonesia (PMI) Kabupaten Nganjuk merupakan salah satu kota uni darah di Jawa Timur. Tugas UDD PMI antara lain:

1. Menyebarluaskan dan mengembangkan aplikasi prinsip dasar Gerakan Palang Merah dan Bulan Sabit Merah serta Hukum Perikemanusiaan Internasional (HPI) dalam masyarakat Indonesia.
2. Melaksanakan pelayanan kepalangmerahan yang bermutu dan tepat waktu, mencakup:
 - a. Bantuan kemanusiaan dalam keadaan darurat
 - b. Pelayanan sosial dan kesehatan masyarakat
 - c. Usaha kesehatan transfusi darah
3. Pembinaan Generasi Muda dalam kepalangmerahan, kesehatan dan kesejahteraan.

Melakukan konsolidasi organisasi, pembinaan potensi dan peningkatan potensi sumber daya manusia dan suber dana untuk menuju PMI yang efektif dan efisien.

(Halaman ini sengaja dikosongkan)

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan adalah data sekunder berupa jumlah permintaan darah tiap golongan di UDD PMI Kota Nganjuk per bulan pada periode Januari 2012 sampai dengan Desember 2016. Data *insample* Januari 2012 sampai Juni 2016 sebanyak 54 observasi, data *outsample* yaitu Juli hingga Desember 2016 sebanyak 6 observasi.

Tabel 3.1 Struktur Data Penelitian

Tahun	Bulan	Permintaan Darah t (kantong)
2012	Januari	Z_1
	Februari	Z_2
	Maret	Z_3

	Oktober	Z_{10}
	November	Z_{11}
	Desember	Z_{12}
2013	Januari	Z_{13}
	Februari	Z_{14}
	Maret	Z_{15}

	Oktober	Z_{22}
	November	Z_{23}
	Desember	Z_{24}
...
2016	Januari	Z_{49}
	Februari	Z_{50}
	Maret	Z_{51}

	Oktober	Z_{58}
	November	Z_{59}
	Desember	Z_{60}


$Z_t(1)$	= permintaan darah golongan O
$Z_t(2)$	= permintaan darah golongan A
$Z_t(3)$	= permintaan darah golongan B
$Z_t(4)$	= permintaan darah golongan AB


3.2 Langkah Analisis

Langkah-langkah analisis pada tugas akhir ini antara lain :

1. Mendiskripsikan data permintaan darah dari januari 2012 sampai Desember 2016 menggunakan statistika desriptif, *boxplot*, dan *timeseries plot*.
2. Membuat *time series plot* dari data *insample* untuk identifikasi stasioneritas dalam varian, jika data tidak stasioner terhadap varian maka dilakukan transformasi *Box-Cox*, jika data tidak stasioner dalam *mean* maka dilakukan *differencing*.
3. Membuat plot ACF dan PACF.
4. Mengidentifikasi dan menduga orde model ARIMA berdasarkan plot ACF dan PACF.
5. Melakukan pengujian estimasi parameter model dan pengujian signifikansi parameter model, jika estimasi parameter tidak signifikan maka dilakukan estimasi parameter dari model dugaan yang lainnya.
6. Melakukan pengujian residual model, dengan beberapa asumsi yang harus dipenuhi antara lain : asumsi *white noise* dengan menggunakan statistik uji *Ljung-Box* dan asumsi kenormalan dengan menggunakan statistik uji *Komogorov Smirnov*.
7. Jika semua asumsi pengujian diatas telah terpenuhi, maka dilakukan pemilihan model peramalan terbaik berdasarkan kriteria rMSE dan sMAPE yang mempunyai nilai terkecil
8. Membuat kombinasi antara model-model ARIMA terbaik yang terbentuk.
9. Setelah tahap tahap terpenuhi dan model peramalan dihasilkan maka dapat dilakukan peramalan permintaan

darah pada bulan Januari sampai Desember 2017. Diagram alir menggambarkan alur penelitian ini dapat dilihat di gambar 3.1 berikut.





Gambar 3.1 Diagram Alir Penelitian

BAB IV ANALISIS DAN PEMBAHASAN

Analisis dan pembahasan mengenai peramalan nilai data permintaan darah tiap golongan darah di PMI Nganjuk dijelaskan pada bab ini. Analisis ini dimulai dengan karakteristik data menggunakan stastika deskriptif, pemodelan ARIMA yang terdiri dari identifikasi model, pengujian model dan pengujian asumsi residual peramalan.

4.1 Karakteristik Data Permintaan Darah di PMI Nganjuk

Karakteristik permintaan masing-masing golongan darah yang akan dilakukan meliputi nilai rata-rata, jumlah maksimum, dan varian dari data yang terlampir pada Lampiran C. Selain itu akan dilakukan analisis karakteristik menggunakan *box-plot* untuk mengetahui persebaran data perbulan. Karakteristik data jumlah permintaan masing-masing golongan darah disajikan dalam Tabel 4.1.


Tabel 4.1 Karakteristik Permintaan Masing-Masing Golongan Darah

Variabel	N	Rata-rata	Minimum	Maksimum	Standar Deviasi
Gol. O	60	312	129	497	89,2
Gol. A	60	177	56	303	55,89
Gol. B	60	237	105	346	66,15
Gol. AB	60	53	16	105	17,34

Tabel 4.1 memberikan informasi bahwa golongan darah O merupakan darah yang paling banyak dibutuhkan di UDD PMI Nganjuk dalam kurun waktu 5 tahun. Permintaan rata-rata darah O satu bulan dalam kurun waktu tersebut sebesar 312. Jumlah tersebut lebih besar dibanding permintaan golongan darah lain. Permintaan darah O terbanyak terjadi pada bulan Agustus 2016, yaitu sebesar 497 kantong sedangkan permintaan terendah 129


kantong. Permintaan tertinggi dan terendah terpaut sangat jauh dapat di lihat dari nilai standar deviasi nya yaitu 89,2.

Selain karakteristik data diatas, akan dilakukan analisis pada karakteristik lain yaitu *box-plot*. *Box-plot* digunakan untuk mengetahui pemusatan data jumlah permintaan masing-masing golongan darah yang meliputi nilai kuartil, minimum dan maksimum, serta melihat ada tidaknya data yang *outlier* atau data pencilan. Grafik box-plot jumlah permintaan masing-masing golongan darah dalam Gambar 4.1




Gambar 4.1 *Box-plot* Jumlah Permintaan Golongan Darah O

Gambar 4.1 menunjukkan bahwa jumlah permintaan golongan darah O terbesar terdapat pada bulan September 2016 yaitu sebesar 494 kantong. Sepanjang tahun 2012-2016 tidak ada permintaan golongan darah O yang ekstrem. Tingkat penyebaran data permintaan atau keragaman permintaan darah O terbesar yaitu terjadi di bulan Agustus dapat dilihat dari panjang *boxplot* bulan Agustus lebih panjang dibanding bulan lain. Selanjutnya penyajian *box-plot* pada jumlah permintaan golongan darah A. Grafik box-plot jumlah permintaan golongan darah A disajikan dalam Gambar 4.2.



Gambar 4.2 *Box-plot* Jumlah Permintaan Golongan Darah A


Gambar 4.2 menunjukkan bahwa jumlah permintaan golongan darah A tertinggi dan terendah terdapat pada bulan Agustus, sehingga persebaran data permintaan atau keragaman terbesar juga terjadi pada bulan tersebut dimana dapat dilihat dari panjang *boxplot* yang terpanjang dibandingkan bulan lain. Kemudian disajikan *box-plot* pada data jumlah permintaan golongan darah B dalam Gambar 4.3.



Gambar 4.3 *Box-plot* Jumlah Permintaan Golongan Darah B

Box-plot pada data permintaan golongan darah B dalam Gambar 4.3 menunjukkan bahwa permintaan terendah terjadi di

bulan Agustus. Tingkat penyebaran data permintaan atau keragaman permintaan darah A terbesar yaitu terjadi di bulan Agustus dapat dilihat dari ukuran *box-plot* terpanjang dibandingkan dengan bulan lain. Selanjutnya penyajian *box-plot* pada jumlah permintaan golongan darah AB. Grafik *box-plot* jumlah permintaan golongan darah AB disajikan dalam Gambar 4.4



Gambar 4.4 *Box-plot* Jumlah Permintaan Golongan Darah AB

Gambar 4.4 menunjukkan permintaan golongan darah AB tertinggi terjadi di bulan Oktober dan permintaan terendah terjadi di bulan Agustus, sebaran data terkecil data permintaan darah AB terendah terdapat pada bulan September dapat dilihat bahwa dari ukuran panjang plot di bulan September yang terpendek dibandingkan bulan lain.


4.2 Pemodelan Permintaan Darah Golongan O

Pemodelan yang dilakukan yakni menggunakan ARIMA *Box-Jenkins* dan diawali dengan membagi data menjadi dua bagian yaitu data *insample* dan data *outsample*. Data *insample* digunakan untuk mengidentifikasi model, pemeriksaan diagnosa (*diagnostic checking*), dan untuk memprediksi data pada tahun 2017. Sedangkan data *outsample* digunakan untuk pemilihan model peramalan terbaik.

4.2.1 Identifikasi Model pada Darah Golongan O


Tahap identifikasi model jumlah permintaan golongan darah O digunakan untuk mengetahui apakah data permintaan golongan darah O telah stasioner atau belum. Stasioneritas terbagi menjadi stasioner dalam varian dan stasioner dalam mean.

Sebelum melakukan pemeriksaan stasioner dalam varian, terlebih dahulu dilihat *time series plot* dan karakteristik dari data. *Time series plot* dari data jumlah permintaan golongan darah O disajikan dalam Gambar 4.5 sebagai berikut.




Gambar 4.5 *Time series plot* Jumlah Permintaan Golongan Darah O

Gambar 4.5 menunjukkan bahwa data jumlah permintaan golongan darah O mulai Januari 2012 sampai bulan Desember 2016 mengalami fluktuasi yang cenderung naik. Permintaan darah melonjak tinggi terjadi pada bulan September 2012 dan hal ini terjadi pada bulan yang sama di tahun 2013 sebesar 159 kantong. Kelonjakan ini disebabkan momentum hari raya idul fitri yang bertepatan di bulan Agustus. Secara visual dapat dikatakan bahwa data tidak stasioner dalam varian dan *mean*. Identifikasi kestasioneran dalam varian menggunakan *Box-cox* dilihat dari nilai *rounded value*. Data dikatakan stasioner dalam varian saat *rounded value* sama dengan 1 atau selang interval dari data permintaan golongan darah O melewati angka 1. Grafik *Box-Cox Transformation* disajikan dalam Gambar 4.6.



Gambar 4.6 Box-Cox Permintaan Golongan Darah O

Gambar 4.6 menunjukkan bahwa nilai *rounded value* yang diperoleh dari pemeriksaan *box-plot* data permintaan golongan darah O adalah sebesar 1 dengan batas bawah dan batas atas berturut-turut sebesar 0,65 dan 2,44. Berdasarkan nilai *rounded value* dan selang interval yang telah melewati nilai 1 maka dapat diidentifikasi bahwa data permintaan golongan darah O sudah stasioner terhadap varians. Selanjutnya pengujian stasioneritas *mean* dilakukan secara visual dan inferensia. Secara visual diidentifikasi menggunakan plot ACF sedangkan secara inferensia dengan pengujian *Dickey-Fuller* untuk memperoleh hasil yang lebih akurat. Plot ACF data permintaan golongan darah O untuk melakukan pemeriksaan secara visual kestasioneran data disajikan dalam Gambar 4.7.



Gambar 4.7 Plot ACF pada Data Permintaan Darah O

Plot ACF yang tertera pada Gambar 4.7 dapat diketahui bahwa plot *Autocorrelation Function* (ACF) turun lambat (*dies down*) dimana nilai ACF didapatkan sesuai dengan Persamaan 2.13 hasil yang dapat dilihat ada Lampiran D1 serta PACF pada Lampiran E1. Hal tersebut mengartikan bahwa data permintaan golongan darah O tidak stasioner terhadap *mean*. Selain pemeriksaan secara visual, perlu dilakukan pemeriksaan stasioneritas terhadap *mean* dengan pengujian *Dickey Fuller* dengan *syntax* pada Lampiran F1 untuk hasil yang lebih akurat.

Hipotesis :

H_0 : Data tidak stasioner dalam *mean* ($\delta = 0$)


H_1 : Data stasioner dalam *mean* ($\delta \neq 0$)

Pada pengujian ini digunakan taraf signifikan sebesar α yakni 0,05 dengan daerah keputusan H_0 ditolak jika tlebih besar dari $t_{\alpha,df}$ dimana $t_{0,05,1}$ sebesar 12,7062 dan *P-value* kurang dari α sebesar 0,05. Berdasarkan hasil pengujian pada Lampiran G1 didapatkan nilai t dari Persamaan 2.11 yang dapat ditampilkan pada Tabel 4.2

Tabel 4.2 Hasil Uji *Dickey Fuller* Sebelum *Differencing*

Variabel	Estimasi Parameter	Standard Error	<i>t</i>	<i>P-value</i>
$Z_t(1)$	-0.01047	0.02656	-0.39	0.6950

Tabel 4.2 menunjukkan bahwa hasil pengujian stasioneritas dengan *Dickey Fuller* didapatkan nilai statistik uji t sebesar $-0,39$ lebih kecil dari nilai $t_{0,05,1}$ yaitu $12,7062$ dan nilai $P\text{-value}$ sebesar $0,6950$ lebih besar daripada nilai signifikan. Berdasarkan dari dua pernyataan sebelumnya, dapat diperoleh keputusan yaitu gagal tolak H_0 dan dapat disimpulkan bahwa data permintaan golongan darah O tidak stasioner dalam *mean*. Perlu dilakukan *differencing* untuk mengatasi ketidakstasioneran dalam *mean*. Gambar 4.8 menunjukkan bahwa data permintaan golongan darah O telah stasioner dalam *mean*, dikarenakan plot *time series* berfluktuasi secara konstan yaitu berada di sekitar nilai rata-rata yaitu permintaan 312 kantong.



Gambar 4.8 Time Series Plot Setelah Differencing

Selain dilakukan pemeriksaan dengan menggunakan *time series* plot, untuk hasil lebih akurat maka perlu dilakukan pengujian *Dickey Fuller* kembali dengan hipotesis dan statistik uji sebagai berikut. *Syntax* terlampir pada Lampiran F2.

Hipotesis :

H_0 : Data tidak stasioner dalam *mean* ($\delta = 0$)

H_1 : Data stasioner dalam *mean* ($\delta \neq 0$)

Pada pengujian ini digunakan taraf signifikan sebesar α yakni $0,05$. dengan daerah keputusan H_0 ditolak jika t lebih besar dari


$t_{\alpha,df}$ dimana $t_{0,05,1}$ sebesar 12,7062 dan P -value kurang dari α sebesar 0,05. Berdasarkan hasil pada Lampiran G2 didapat nilai yang dapat dilihat pada Tabel 4.3


Tabel 4.3 Hasil Uji *Dickey Fuller* Setelah *Differencing*

Variabel	Estimasi Parameter	Standard Error	t	P -value
$Z_t(1)$	-1.55337	-1.55337	-13.44	<0,0001

Berdasarkan nilai t yang lebih kecil dari 12,7062 dan P -value lebih kecil daripada α sebesar 0,05 maka disimpulkan yaitu H_0 ditolak artinya data permintaan golongan darah O telah stasioner dalam *mean*.

Setelah data stasioner dalam *mean* dan *varians*, langkah selanjutnya yaitu menduga orde model ARIMA. Hal ini dapat dilakukan secara visual dengan melihat plot ACF dan PACF dari data permintaan darah golongan O yang telah stasioner dalam *mean* dan *varians*. Berikut merupakan plot ACF dan PACF setelah *differencing* ditampilkan pada Gambar 4.9.






Gambar 4.9 (a) Plot ACF, (b) Plot PACF Permintaan Darah O yang Telah Stasioner

Gambar 4.9 menunjukkan bahwa plot ACF *cut off* setelah lag 1 karena memiliki nilai autokorelasi yang besar dengan hasil selengkapnya dapat dilihat pada Lampiran D2, sehingga model dugaan yang dapat diidentifikasi yaitu ARIMA (0,1,1), sedangkan pada plot PACF terjadi *dies down* secara tepat pada lag awal yaitu lag 1, dan 2 yang memiliki nilai autokorelasi terbesar seperti yang tercantum di Lampiran E2 sehingga model yang dapat diduga yaitu ARIMA (2,1,0).

Data permintaan golongan darah merupakan data bulanan, sehingga ada kemungkinan musiman. Maka dari itu perlu dilihat plot ACF dan PACF yang telah *differencing* 12. Dimana *syntax* SAS pengujian *Dickey fuller* sesudah *differencing* 12 terlampir pada lampiran F1.



Gambar 4.10 (a) Plot ACF, (b) Plot PACF Permintaan Darah O Differencing 12

Gambar 4.10 menunjukkan bahwa plot ACF *cut off* setelah lag 1 karena memiliki nilai autokorelasi yang besar dengan hasil selengkapnya dapat dilihat pada Lampiran E3, sehingga model dugaan yang dapat diidentifikasi yaitu $ARIMA(0,1,1)(0,1,0)^{12}$ dan $(0,1,1)(1,0,0)^{12}$ sedangkan pada plot PACF juga terjadi *cut off* setelah lag 1 yang memiliki nilai autokorelasi terbesar seperti yang tercantum di Lampiran E4 sehingga model yang dapat diduga yaitu $ARIMA(1,1,0)(0,1,0)^{12}$.

4.2.2 Estimasi dan Pengujian Parameter pada Permintaan Darah Golongan O

Setelah melakukan identifikasi orde ARIMA, selanjutnya dilakukan estimasi parameter data permintaan golongan darah O. Estimasi dilakukan untuk mengetahui apakah model dugaan telah signifikan atau tidak. Metode estimasi parameter yang digunakan yaitu *Conditional Least Square* (CLS). Estimasi dan pengujian parameter pada masing-masing model ARIMA dinyatakan dengan hipotesis sebagai berikut

$H_0: \phi = 0$ atau $\theta = 0$ (Parameter AR atau MA tidak signifikan)

$H_1: \phi \neq 0$ atau $\theta \neq 0$ (Parameter AR atau MA signifikan)

Pada pengujian ini digunakan taraf signifikan sebesar α sebesar 0,05. dengan daerah keputusan H_0 ditolak jika $|t|$ lebih besar dari $t_{\alpha/2, n-m}$; dan *P-value* kurang dari α . Berdasarkan *syntax* H, H2, H3 dan H4 yang menghasilkan Lampiran I1, I2, I3 dan I4 didapat nilai t hitung yang mengacu pada Persamaan 2.19, kemudian dilakukan estimasi dan pengujian parameter ditampilkan pada Tabel 4.4.

Tabel 4.4 Parameter pada Permintaan Darah Golongan O

Model ARIMA	Parameter	Estimasi	t	t-tabel	<i>P-value</i>	Keputusan
(2,1,0)	ϕ_1	-0,68406	-4,96	2,007	<0,0001	Sig.
	ϕ_2	-0,24292	-1,76	2,007	0,0846	Tidak Sig.
(0,1,1)	θ_1	0.63920	5,95	2,006	<0,0001	Sig.
(0,1,1)(1,0,0) ¹²	θ_1	0,651113	5,97	2,007	<0,0001	Sig.
	ϕ_1	0,1154	0,76	2,007	0,4536	Tidak Sig.
(0,1,1)(0,1,0) ¹²	θ_1	0,64582	5,29	2,006	<0,0001*	Sig.

*Sig=signifikan

Tabel 4.4 menunjukkan bahwa dari keempat model dugaan yang diperoleh dari identifikasi lag-lag pada plot ACF dan plot PACF data permintaan golongan darah O, model-model yang telah

signifikan adalah ARIMA (0,1,1), dan ARIMA (0,1,1)(0,1,0)¹² sedangkan ARIMA ARIMA (0,1,1)(1,0,0)¹² memiliki peluang untuk memberikan nilai RMSE lebih kecil maka dapat dilanjutkan ke pengujian residual.

4.2.3 Analisis Uji Asumsi Residual pada Permintaan Darah Golongan O

Pada uji estimasi dan signifikansi parameter, pada model ARIMA (0,1,1), ARIMA (0,1,1)(0,1,0)¹² dan ARIMA (0,1,1)(1,0,0)¹² model-model tersebut diuji residualnya menggunakan asumsi *white noise* dan berdistribusi normal. Asumsi residual (*error*) *white noise* adalah asumsi dimana pada residual tidak terdapat gangguan-gangguan seperti adanya korelasi atau model tertentu pada residual. Dengan kata lain, jika residual telah *white noise* artinya residual model telah bersih.

Pengujian untuk melihat residual telah *white noise* dapat dilakukan dengan menggunakan hipotesis dan statistik uji *Ljung-Box* sebagai berikut.

Hipotesis :

$$H_0 : \rho_{a_{r1}} = \rho_{a_{r2}} = \rho_{a_{r3}} = \dots = \rho_{a_{rk}} = 0 \quad (\text{residual } \textit{white noise})$$

$$H_1 : \text{minimal ada satu } \rho_{a_{rk}} \neq 0 \text{ untuk } k = 1, 2, \dots, K \\ (\text{residual tidak } \textit{white noise})$$

Taraf signifikan yang digunakan yaitu $\alpha = 0,05$ dan H_0 ditolak jika nilai χ^2 lebih besar dari $\chi^2_{(\alpha; k-p-q)}$ dan $P\text{-value}$ kurang dari $\alpha = 0,05$. Berdasarkan *syntax* pada Lampiran H1 sampai H4 yang menghasilkan *output* di Lampiran I1 sampai I4 didapatkan nilai χ^2 sesuai dengan Persamaan 2.21. Berikut hasilnya.

Tabel 4.5 Asumsi *White Noise* pada Permintaan Darah Golongan O

Model ARIMA	χ^2	χ^2_{tabel}	$P\text{-value}$	Kesimpulan
(0,1,1)	4.65	11,07	0.4597	<i>White noise</i>
	13.92	19,68	0.2374	<i>White noise</i>

	19.66	27,59	0.2918	White noise
	25.25	35,17	0.3376	White noise
Model ARIMA	χ^2	χ^2_{tabel}	P-value	Kesimpulan
	9.80	12,59	0.0811	White noise
(0,1,1)(0,1,0) ¹²	29.48	21,03	0.0019	Tidak White noise
	41.30	28,87	0.0008	Tidak White noise
	44.74	36,42	0.0043	Tidak White noise
	5,44	9,48772	0,2454	White noise
(0,1,1)(1,0,0) ¹²	15,27	18,307	0,1225	White noise
	2,61	26,296	0,1244	White noise
	27,70	33,9244	0,1860	White noise

Hasil pengujian asumsi *white noise* dapat dilihat pada Tabel 4.5. Model ARIMA (0,1,1) dan ARIMA (0,1,1)(1,0,0)¹² yang tertera pada dapat diketahui bahwa model yang terbentuk memenuhi asumsi *white noise* karena nilai χ^2 lebih besar dari nilai χ^2_{tabel} dan nilai *p-value* yang dihasilkan lebih besar dari 0,05.

Model ARIMA (0,1,1) dan (0,1,1)(1,0,0)¹² dan akan diuji asumsi kenormalannya. Asumsi residual berdistribusi normal ini menggunakan statistik uji *Kolmogorov-Smirnov*. Dari Tabel 4.6 dapat diambil keputusan bahwa residual dari model ARIMA (0,1,1) dan ARIMA (0,1,1)(1,0,0)¹² berdistribusi normal. Berikut adalah hipotesis yang digunakan dalam pengujian ini.

Hipotesis :

$H_0 : F_n(a_t) = F_0(a_t)$ (Residual berdistribusi normal)

$H_1 : F_n(a_t) \neq F_0(a_t)$ (Residual tidak berdistribusi normal)

Taraf signifikan yang digunakan sebesar α sebesar 0,05 dengan daerah penolakan H_0 adalah jika $D > D_{n,(1-\alpha)}$ selain itu juga dapat dilihat dari nilai *P-value* kurang dari α . Berdasarkan pada Lampiran I2 didapatkan nilai D_{hitung} sesuai dengan Persamaan 2.22 hasil pengujiannya asumsi residual berdistribusi normal.

Tabel 4.6 Asumsi Distribusi Normal pada Permintaan Darah Golongan O

Model ARIMA	D_{hitung}	D_{tabel}	$P-value$	Keputusan
(0,1,1)	0.069878	0,1848	>0.1500	Berdistribusi Normal
(0,1,1)(1,0,0) ¹²	0,077022	0,1848	>0.1500	Berdistribusi Normal

Tabel 4.6 menunjukkan bahwa pada model ARIMA yang telah signifikan memenuhi asumsi distribusi normal. Model yang dapat meramalkan permintaan golongan darah O adalah ARIMA (0,1,1) dan (0,1,1)(1,0,0)¹².

4.2.4 Pemilihan Model Terbaik pada Permintaan Darah Golongan O

Model ARIMA yang didapatkan selanjutnya akan dipilih untuk digunakan sebagai model yang dapat memprediksi permintaan golongan darah O satu tahun kedepan selama tahun 2017. Pemilihan model dilakukan dengan menggunakan empat kriteria pemilihan model terbaik, dengan hasil analisis pada Tabel 4.5. Penghitungan manual pada Lampiran J1 sampai J4. Dikarenakan model yang memenuhi asumsi hanya 1 model yaitu ARIMA (0,1,1) maka menggunakan 4 kriteria pemilihan model terbaik hanya untuk penambah informasi.

Tabel 4.7 Pemilihan Model Terbaik Permintaan Golongan Darah O

Model	<i>Outsample</i>		<i>Insample</i>	
	sMAPE	RMSE	AIC	SBC
(0,1,1)	9,94	58,448	551.3521	553.3034
(0,1,1)(1,0,0) ¹²	0,09	53,784	562,4537	566,3943

Tabel 4.7 menunjukkan bahwa hasil perhitungan kriteria pemilihan model terbaik. Karena model yang memenuhi asumsi residual, maka yang terpilih adalah model ARIMA (0,1,1)(1,0,0)¹².

Secara umum model ARIMA (0,1,1)(1,0,0)¹² adalah sebagai berikut.

$$\begin{aligned}
(1 - \Phi_1 B^{12})(1 - B)\dot{Z}_t &= (1 - \theta_1 B)a_t \\
(1 - B - \Phi_1 B^{12} + \Phi_1 B^{13})\dot{Z}_t &= a_t - \theta_1 a_{t-1} \\
\dot{Z}_t - \dot{Z}_{t-1} - \Phi_1 \dot{Z}_{t-12} + \Phi_1 \dot{Z}_{t-13} &= a_t - \theta_1 a_{t-1} \\
\dot{Z}_t &= \dot{Z}_{t-1} + \Phi_1 \dot{Z}_{t-12} - \Phi_1 \dot{Z}_{t-13} + a_t - \theta_1 a_{t-1} \\
Z_t - \mu &= (Z_{t-1} - \mu) + \Phi_1 (Z_{t-12} - \mu) - \Phi_1 (Z_{t-13} - \mu) + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + \Phi_1 Z_{t-12} - \Phi_1 \mu - \Phi_1 Z_{t-13} + \Phi_1 \mu + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + \Phi_1 Z_{t-12} - \Phi_1 Z_{t-13} + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + 0,11540Z_{t-12} - 0,11540Z_{t-13} + a_t - 0,65113a_{t-1}
\end{aligned}$$

Dari model matematis diatas diketahui bahwa permintaan darah golongan O dipengaruhi oleh data permintaan darah O 1, 12 dan 13 bulan sebelumnya serta di pengaruhi kesalahan peramalan 1 bulan lalu. *Output* terlampir pada Lampiran AF1.

Tabel 4.8 Hasil Prediksi pada Permintaan Darah Golongan O Tahun 2017

Bulan	Batas Bawah	Nilai Prediksi	Batas Atas
Januari	280	403	527
Februari	277	405	533
Maret	275	407	538
April	270	406	542
Mei	262	402	542
Juni	262	406	549
Juli	255	405	555
Agustus	251	405	560
September	247	406	565
Oktober	242	405	567
November	238	405	572
Desember	234	405	576

Tabel 4.8 menunjukkan bahwa hasil prediksi permintaan golongan darah O pada tahun 2017 dimana bulan Maret


diprediksi terjadi kebutuhan darah O tertinggi sebanyak 407 kantong, dengan persediaan minimal 275 kantong dan persediaan terbanyak yang 538 kantong. Berdasarkan nilai ramalan darah O rata-rata permintaannya 405 kantong dengan batas bawah dan batas atas yang bervariasi dimana nilai nilai nya lebih besar dibanding nilai minimum dan nilai maksimum data permintaan 2012-2016. Diprediksi permintaan darah O meningkat dibandingkan data permintaan tahun 2012-2016.

4.3 Pemodelan Permintaan Darah Golongan A

Pemodelan yang dilakukan kedua yaitu permintaan golongan darah A.

4.3.1 Identifikasi Model pada Permintaan Darah Golongan A


Time series plot dari data jumlah permintaan golongan darah O disajikan dalam Gambar 4.5 sebagai berikut.



Gambar 4.11 Time Series Plot Jumlah Permintaan Golongan Darah A

Gambar 4.11 menunjukkan bahwa data jumlah permintaan golongan darah A mulai Januari 2012 sampai bulan Desember 2016 mengalami fluktuasi yang cenderung naik. Sama halnya permintaan darah O, permintaan golongan darah A juga mengalami permintaan tertinggi di bulan Januari tahun 2016 dan permintaan terendah yaitu di bulan Juni 2012.


Grafik *Box-Cox Transformation* disajikan dalam Gambar 4.12.



Gambar 4.12 *Box-Cox* Permintaan Golongann Darah A

Plot *Box-Cox* yang tertera pada Gambar 4.12 menunjukkan bahwa nilai λ (*rounded value*) sebesar 0,50, sedangkan nilai *rounded value* sebenarnya hasil pembulatan dari nilai estimate yaitu sebesar 0,59. Nilai *upper CL* sebesar 1,31 sudah lebih besar dari 1 sehingga dapat disimpulkan bahwa data telah stasioner terhadap varian walaupun nilai *rounded value*nya rendah. Maka data tidak perlu ditransformasi.

Secara visual diidentifikasi menggunakan plot ACF sedangkan secara inferensia dengan pengujian *Dickey-Fuller* untuk memperoleh hasil yang lebih akurat. Plot ACF data permintaan golongan darah A untuk melakukan pemeriksaan secara visual kestasioneran data disajikan dalam Gambar 4.13.



Gambar 4.13 Plot ACF pada Data Permintaan Darah Golongan A

Gambar 4.13 menunjukkan bahwa pola plot secara visual turun lambat (*dies down*) . Hal tersebut mengartikan bahwa data tidak stasioner terhadap *mean*, sehingga harus dilakukan *differencing* pada data asli permintaan darah golongan A. *Output* ACF dan PACF terlampir pada Lampiran K1 dan L1.

Perlu dilakukan pemeriksaan stasioneritas terhadap *mean* dengan pengujian *Dickey Fuller* untuk hasil yang lebih akurat. Hipotesis :

H_0 : Data tidak stasioner dalam *mean* ($\delta = 0$)


H_1 : Data stasioner dalam *mean* ($\delta \neq 0$)

Pada pengujian ini digunakan taraf signifikan α sebesar 0,05. dengan daerah keputusan H_0 ditolak jika t lebih besar dari $t_{\alpha,df}$; dimana $t_{0,05,1}$ yakni 12,7062 dan *P-value* kurang dari α . Berdasarkan hasil pengujian menggunakan *syntax* terlampir pada M1 menghasilkan pada Lampiran N1 didapatkan nilai t dari Persamaan 2.11 yang dapat ditampilkan pada Tabel 4.2

Tabel 4.9 Hasil Uji *Dickey Fuller* Sebelum *Differencing*

Variabel	Estimasi Parameter	Standar d Error	t	<i>P.value</i>
$Z_t(2)$	-0.03692	0.04263	-0.87	0.3904

Tabel 4.9 menunjukkan bahwa hasil pengujian stasioneritas dengan *Dickey Fuller* didapatkan nilai statistik uji t sebesar $-0,87$ kurang dari nilai $t_{0,05,1}$ yaitu $12,7062$ dan nilai P -value sebesar $0,3904$ lebih besar daripada nilai signifikan. Berdasarkan dari dua pernyataan sebelumnya, dapat diperoleh keputusan yaitu gagal tolak H_0 dan dapat disimpulkan bahwa data permintaan golongan darah A tidak stasioner dalam *mean*. Perlu dilakukan *differencing* untuk mengatasi ketidakstasioneran dalam *mean*. Gambar 4.14 menunjukkan bahwa data permintaan golongan darah A telah stasioner dalam *mean*, dikarenakan *time series plot* berfluktuasi secara konstan.



Gambar 4.14 Time Series Plot Setelah Differencing

Hasil lebih akurat maka perlu dilakukan pengujian *Dickey Fuller* kembali dengan hipotesis dan statistik uji sebagai berikut. Dimana *syntax* terlampir pada Lampiran M2 menghasilkan Lampiran N2 selain itu nilai ACF dan PACF setelah *differencing* terlampir pada Lampiran K2 dan L2.

Hipotesis :

H_0 : Data tidak stasioner dalam *mean* ($\delta = 0$)

H_1 : Data stasioner dalam *mean* ($\delta \neq 0$)

Pada pengujian ini digunakan taraf signifikan sebesar α sebesar $0,05$, dengan daerah keputusan H_0 ditolak jika t lebih besar dari $t_{\alpha,df}$ dimana $t_{0,05,1}$ sebesar $12,7062$ dan P -value kurang dari α .

Berdasarkan hasil pada Lampiran N2 didapat nilai yang dapat dilihat pada Tabel 4.10

Tabel 4.10 Hasil Uji *Dickey Fuller* Setelah *Differencing*


Variabel	Estimasi Parameter	Standar d Error	<i>t</i>	P-value
$Z_t(2)$	-1,60988	0,1114	-14,48	<0,0001


Berdasarkan nilai *t* yang lebih besar dari 12,7062 dan P-value lebih kecil daripada α sebesar 0,05 maka disimpulkan yaitu H_0 gagal ditolak artinya data permintaan golongan darah A belum stasioner dalam *mean*. Maka dilakukan *differencing* 12 karena diduga data musiman dimana *syntax* terlampir pada Lampiran M3 yang menghasilkan nilai pada Lampiran N3.

Tabel 4.11 Hasil Uji *Dickey Fuller* Setelah *Differencing* 12

Variabel	Estimasi Parameter	Standar d Error	<i>t</i>	P-value
$Z_t(2)$	-1,58219	0,13449	-11,76	<0,0001

Berdasarkan nilai *t* yang lebih kecil dari 12,7062 dan P-value lebih kecil daripada α maka disimpulkan yaitu H_0 ditolak artinya data permintaan golongan darah A telah stasioner dalam *mean*.





Gambar 4.15 (a) Plot ACF dan (b) plot PACF Setelah *Differencing* Lag 12

Gambar 4.10 menunjukkan bahwa plot ACF *cut off* setelah lag 12 karena memiliki nilai autokorelasi yang besar dengan hasil selengkapnya dapat dilihat pada Lampiran L4, sehingga model dugaan yang dapat diidentifikasi yaitu $ARIMA(0,1,1)(0,1,0)^{12}$, sedangkan pada plot PACF juga terjadi *cut off* setelah lag 1, lag 3 dan lag 4 yang memiliki nilai autokorelasi terbesar seperti yang tercantum di Lampiran L4 sehingga model yang dapat diduga yaitu $ARIMA(1,1,0)(0,1,0)^{12}$, $(3,1,0)(0,1,0)^{12}$, $(4,1,0)(0,1,0)^{12}$, $([1,3,4],1,0)$ dan $([1,3,4],1,0)(0,1,0)^{12}$.

4.3.2 Estimasi dan Pengujian Parameter pada Permintaan Darah Golongan A

Setelah melakukan identifikasi orde ARIMA, selanjutnya dilakukan estimasi parameter data permintaan golongan darah A. Estimasi dilakukan untuk mengetahui apakah model dugaan telah signifikan atau tidak. Metode estimasi parameter yang digunakan yaitu *Conditional Least Square* (CLS). Estimasi dan pengujian parameter pada masing-masing model ARIMA dinyatakan dengan hipotesis sebagai berikut

Hipotesis :

$$H_0 : \phi = 0 \text{ atau } \theta = 0 (\text{Parameter AR atau MA tidak signifikan})$$

$H_1 : \phi \neq 0$ atau $\theta \neq 0$ (Parameter AR atau MA signifikan)

Pada pengujian ini digunakan taraf signifikan sebesar α yakni 0,05. dengan daerah keputusan H_0 ditolak jika $|t| > t_{\alpha/2, n-m}$; dan $P\text{-value}$ kurang dari $\alpha = 0,05$. Berdasarkan *syntax* Lampiran O1 sampai O5 yang menghasilkan Lampiran P1 sampai P5 didapat nilai t hitung yang bengacu pada Persamaan 2.19, kemudian dilakukan estimasi dan pengujian parameter ditampilkan pada Tabel 4.12.

Tabel 4.12 Parameter pada Permintaan Darah Golongan A

Model ARIMA	Parameter	Estimasi	t	t-tabel	<i>P-value</i>	Keputusan
([1,3,4],1,0)	ϕ_1	-0.58321	-4.48	2,008	<0,0001	Sig.
	ϕ_2	-0.36015	-2.25	2,008	0,0304	Sig.
	ϕ_3	-0.33177	-2.02	2,008	0,0508	Sig.
$(0,1,1)(0,1,0)^{12}$	θ_1	0.84448	9.88	2,006	<0.0001	Sig.
$(1,1,0)(0,1,0)^{12}$	ϕ_1	-0.56433	-4.32	2,006	<0.0001	Sig.
$(3,1,0)(0,1,0)^{12}$	ϕ_1	-0.30967	-1.90	2,006	0.0647	Tidak Sig.
$(4,1,0)(0,1,0)^{12}$	ϕ_1	0.04727	0.28	2,006	0.7836	Tidak Sig.
$([1,3,4],1,0)(0,1,0)^{12}$	ϕ_1	-0.58321	-4.48	2,008	<0.0001	Sig.
	ϕ_2	-0.36015	-2.25	2,008	0.0304	Sig.
	ϕ_3	-0.33177	-2.02	2,008	0.0508	Sig.

*Sig=signifikan

Tabel 4.7 menunjukkan bahwa tiga model dugaan yang diperoleh dari identifikasi lag-lag pada plot ACF dan plot PACF data permintaan golongan darah A yang signifikan yaitu $(0,1,1)(0,1,0)^{12}$, $(1,1,0)(0,1,0)^{12}$, $([1,3,4],1,0)$ dan $([1,3,4],1,0)(0,1,0)^{12}$.

4.3.3 Analisis Uji Asumsi Residual pada Permintaan Darah Golongan A

Pengujian untuk melihat residual telah *white noise* dapat dilakukan dengan menggunakan hipotesis dan statistik uji *Ljung-Box* sebagai berikut.

Hipotesis :

$$H_0 : \rho_{a_{t1}} = \rho_{a_{t2}} = \rho_{a_{t3}} = \dots = \rho_{a_{tk}} = 0 \quad (\text{residual } \textit{white noise})$$

$$H_1 : \text{minimal ada satu } \rho_{a_{tk}} \neq 0 \text{ untuk } k = 1, 2, \dots, K \quad (\text{residual tidak } \textit{white noise})$$

Taraf signifikan yang digunakan yaitu α sebesar 0,05 dan H_0 ditolak jika nilai χ^2 lebih besar dari $\chi^2_{(\alpha; k-p-q)}$ dan *P-value* kurang dari $\alpha = 0,05$. Berdasarkan hasil Lampiran P1, P2 dan P5 didapatkan nilai χ^2 sesuai dengan Persamaan 2.21. Hasil uji *Ljung-Box* dapat dilihat pada Tabel 4.5 yang menunjukkan bahwa pada model

Tabel 4.13 Asumsi *White Noise* pada Permintaan Darah Golongan A

Model ARIMA	χ^2	χ^2_{tabel}	<i>P-value</i>	Kesimpulan
([1,3,4],1,0)	9,55	7,814	0,0229	Tidak <i>White noise</i>
	10,71	16,918	0,2963	Tidak <i>White noise</i>
	21,91	24,995	0,1103	Tidak <i>White noise</i>
	34,04	32,670	0,0359	Tidak <i>White noise</i>
(0,1,1)(0,1,0) ¹²	7.66	11,0705	0.1758	<i>White noise</i>
	21.41	19,67514	0.0294	Tidak <i>White noise</i>
	27.87	27,58711	0.0465	Tidak <i>White noise</i>
	35.56	35,17246	0.0457	Tidak <i>White noise</i>
(1,1,0)(0,1,0) ¹²	18.54	11,0705	0.0023	Tidak <i>White noise</i>
	44.09	19,67514	<0.0001	Tidak <i>White noise</i>
	57.41	27,58711	<0.0001	Tidak <i>White noise</i>
	73.26	35,17246	<0.0001	Tidak <i>White noise</i>

Model ARIMA	χ^2	χ^2_{tabel}	P-value	Kesimpulan
([1,3,4],1,0)(0,1,0) ¹	12.22	7,814728	0.0067	Tidak <i>White noise</i>
	29.14	16,91898	0.0006	Tidak <i>White noise</i>
	40.56	24,99579	0.0004	Tidak <i>White noise</i>
	56.61	28,8693	<0.0001	Tidak <i>White noise</i>

Dikarenakan pada pengujian asumsi *white noise* tidak ada yang gagal tolak H_0 maka pengujian distribusi normal tetap dilanjutkan untuk ketiga model ARIMA tersebut. Hal ini dikarenakan pada Gambar *boxplot* 4.2, data permintaan darah A tidak memiliki nilai pencilan selain itu pada Gambar 4.14 *timeseries plot* juga menunjukkan bahwa data tidak ada yang terlalu tinggi atau rendah.

Asumsi selanjutnya yang harus dipenuhi adalah residual harus berdistribusi normal, hal ini dapat diketahui dengan menggunakan uji *kolmogorov smirnov*. Berikut adalah hipotesis yang digunakan dalam pengujian ini.

Hipotesis :

$H_0 : F_n(a_t) = F_0(a_t)$ (Residual berdistribusi normal)

$H_1 : F_n(a_t) \neq F_0(a_t)$ (Residual tidak berdistribusi normal)

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha = 0,05$. dengan daerah keputusan H_0 ditolak jika $D > D_{n,(1-\alpha)}$ selain itu juga bisa dilihat dari nilai P-value kurang dari $\alpha = 0,05$. Berdasarkan hasil pada Lampiran P1, P2 dan P5 didapatkan nilai D_{hitung} sesuai dengan Persamaan 2.22. Hasil pengujian asumsi residual berdistribusi normal dengan menggunakan uji *Kolomogorov Smirnov* dapat dilihat pada Tabel 4.14

Tabel 4.14 Asumsi Distribusi Normal pada Permintaan Darah Golongan A

Model ARIMA	D_{hitung}	D_{Tabel}	P-value	Keputusan
([1,3,4],1,0)	0,1095	0,1848	0,1109	Berdistribusi Normal
(0,1,1)(0,1,0) ¹²	0.093	0,1848	0,1500	Berdistribusi Normal
(1,1,0)(0,1,0) ¹²	0.103	0,1848	0,1500	Berdistribusi Normal
([1,3,4],1,0)(0,1,0) ¹²	0.088	0,1848	0,1500	Berdistribusi Normal

Tabel 4.14 menunjukkan bahwa pada model ARIMA yang telah signifikan memenuhi asumsi distribusi normal maka pemenuhan asumsi *white noise* dapat diabaikan. Model ARIMA yang tidak memenuhi *white noise* dapat menggunakan aplikasi peramalan semiparameter yang tidak menjadi pembahasan pada tugas akhir ini. Maka ketidak pemenuhan *white noise* dapat diabaikan dan dilanjutkan dengan pemilihan model terbaik.

4.3.4 Pemilihan Model Terbaik

Model ARIMA yang didapatkan selanjutnya akan dipilih untuk digunakan sebagai model yang dapat memprediksi permintaan golongan darah A satu tahun kedepan selama tahun 2017 pada Lampiran Q1 sampai Q8.

Tabel 4.15 Pemilihan Model Terbaik Permintaan Golongan Darah A

Model ARIMA	<i>Outsample</i>		<i>Insample</i>	
	sMAPE	RMSE	AIC	SBC
([1,3,4],1,0)	0,1055	34,876	554,292	560,20
(0,1,1)(0,1,0) ¹²	0,175484	45,786	441.2054	442.919
(1,1,0)(0,1,0) ¹²	0,2727	62,098	450.385	452.0986
([1,3,4],1,0)(0,1,0) ¹²	0,163	41,150	448.3348	453.4755

Tabel 4.15 menunjukkan hasil perhitungan kriteria pemilihan model terbaik. Berdasarkan kriteria *in-sample* yaitu AIC dan SBC menunjukkan model terbaik adalah model ARIMA (0,1,1)(0,1,0)¹² karena didapatkan nilai AIC paling kecil sesuai dengan Persamaan 2.28 dan SBC sesuai dengan Persamaan 2.29 dengan hasil selengkapnya dapat dilihat pada Lampiran Q, sedangkan untuk nilai RMSE dan sMAPE terkecil juga terdapat pada model ARIMA([1,3,4,1,0) sehingga dapat disimpulkan bahwa model terbaik yang didapatkan yaitu ARIMA ([1,3,4],1,0).

Secara umum model ARIMA ([1,3,4],1,0) adalah sebagai berikut.

$$(1 - \phi_1 B - \phi_2 B^3 - \phi_3 B^4)(1 - B)\dot{Z}_t = a_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2 - \phi_2 B^3 + \phi_2 B^4 - \phi_3 B^4 + \phi_3 B^5)\dot{Z}_t = a_t$$

$$\begin{aligned}
& \dot{Z}_t - B\dot{Z}_t - \phi_1 B\dot{Z}_t + \phi_1 B^2 \dot{Z}_t - \phi_2 B^3 \dot{Z}_t + \phi_2 B^4 \dot{Z}_t - \phi_3 B^4 \dot{Z}_t \\
& + \phi_3 B^5 \dot{Z}_t = a_t \\
& \dot{Z}_t = B\dot{Z}_t + \phi_1 B\dot{Z}_t - \phi_1 B^2 \dot{Z}_t + \phi_2 B^3 \dot{Z}_t - \phi_2 B^4 \dot{Z}_t \\
& + \phi_3 B^4 \dot{Z}_t - \phi_3 B^5 \dot{Z}_t + a_t \\
& (Z_t - \mu) = (Z_{t-1} - \mu) - \phi_1 (Z_{t-1} - \mu) - \phi_1 (Z_{t-2} - \mu) + \phi_2 (Z_{t-3} - \mu) \\
& - \phi_2 (Z_{t-4} - \mu) + \phi_3 (Z_{t-4} - \mu) - \phi_3 (Z_{t-5} - \mu) + a_t \\
& Z_t = Z_{t-1} - \phi_1 Z_{t-1} - \phi_1 Z_{t-2} + \phi_2 Z_{t-3} - \phi_2 Z_{t-4} + \phi_3 Z_{t-4} \\
& - \phi_3 Z_{t-5} + a_t \\
& Z_t = Z_{t-1} + 0,58321Z_{t-1} + 0,5832Z_{t-2} - 0,36015Z_{t-3} \\
& + 0,36015\phi_2 Z_{t-4} - 0,33177Z_{t-4} + 0,33177Z_{t-5} + a_t
\end{aligned}$$

Berdasarkan model matematis diatas diketahui bahwa permintaan darah A dipengaruhi oleh permintaan 1 sampai 5 bulan sebelumnya. Sesuai hasil peramalan pada Lampiran AF2, Januari dan Maret diperkirakan butuh 241 kantong darah A, selain itu 242 kantong. Diprediksi rata-rata permintaan di 2017 meningkat dibanding permintaan 2012-2016.

Tabel 4.16 Hasil Prediksi pada Permintaan Darah Golongan A Tahun 2017


Bulan	Batas Bawah	Nilai Prediksi	Batas Atas
Januari	98	241	384
Februari	91	242	392
Maret	84	241	399
April	78	242	406
Mei	72	242	412
Juni	65	242	418
Juli	60	242	424
Agustus	54	242	429
September	48	242	435
Oktober	43	242	440
November	38	242	446
Desember	33	242	451

4.4 Pemodelan Permintaan Darah Golongan B

Pemodelan yang dilakukan ketiga yaitu permintaan golongan darah B.

4.4.1 Identifikasi Model pada Permintaan Darah Golongan B


Time series plot dari data jumlah permintaan golongan darah B disajikan dalam Gambar 4.5 sebagai berikut.



Gambar 4.16 Plot *Box-Cox* pada Permintaan Darah Golongan B


Gambar 4.16 menunjukkan bahwa data jumlah permintaan golongan darah B mulai Januari 2012 sampai bulan Desember 2016 tidak stasioner dalam *mean*.

Grafik *Box-Cox Transformation* disajikan dalam Gambar 4.17.



Gambar 4.17 Plot *Box-Cox* pada Permintaan Darah Golongan B

Plot *Box-Cox* pada Gambar 4.17 menginformasikan bahwa permintaan darah golongan B di Nganjuk sudah stasioner dalam varians. Hal tersebut dapat diketahui melalui nilai λ yang bernilai 1 serta nilai *Upper CL* lebih besar dari 1 yaitu 2. Selanjutnya dapat dilakukan pengecekan stasioner terhadap *mean* dengan menggunakan plot ACF. Plot ACF pada data permintaan darah golongan B menunjukkan bahwa data tersebut tidak stasioner dalam *mean* dimana *output* Z1 dan Z2.



Gambar 4.18 Plot ACF pada Permintaan Darah Golongan B

Gambar 4.18 menunjukkan bahwa pola plot secara visual turun lambat (*dies down*). Hal tersebut mengartikan bahwa data tidak stasioner terhadap *mean*, sehingga harus dilakukan *differencing* pada data asli permintaan darah golongan B. *Output* ACF terlampir pada Lampiran R1.

Perlu dilakukan pemeriksaan stasioneritas terhadap *mean* dengan pengujian *Dickey Fuller* untuk hasil yang lebih akurat dimana *syntax* terlampir pada Lampiran T1 dan *output* pada Lampiran U1.

Hipotesis :

H_0 : Data tidak stasioner dalam *mean* ($\delta = 0$)

H_1 : Data stasioner dalam *mean* ($\delta \neq 0$)

Pada pengujian ini digunakan taraf signifikan α sebesar 0,05. dengan daerah keputusan H_0 ditolak jika t lebih besar dari $t_{\alpha, df}$,

dimana nilai $t_{0,05,1}$ yaitu 12,7062 dan *P-value* kurang dari α . Berdasarkan hasil pengujian pada Lampiran U1 didapatkan nilai t dari Persamaan 2.11 yang dapat ditampilkan pada Tabel 4.17.

Tabel 4.17 Hasil Uji *Dickey Fuller* Sebelum *Differencing*

Variabel	Estimasi Parameter	Standar d Error	t	<i>P-value</i>
$Z_t(3)$	-0.01368	0.02663	-0.51	0.6097


Tabel 4.17 menunjukkan bahwa hasil pengujian stasioneritas dengan *Dickey Fuller* didapatkan nilai statistik uji t sebesar -0,51 kurang dari nilai $t_{0,05,1}$ yaitu 12,7062 dan nilai *P-value* sebesar 0,6097 lebih besar daripada nilai signifikan. Berdasarkan dari dua pernyataan sebelumnya, dapat diperoleh keputusan yaitu gagal tolak H_0 dan dapat disimpulkan bahwa data permintaan golongan darah B tidak stasioner dalam *mean*. Perlu dilakukan *differencing* untuk mengatasi ketidakstasioneran dalam *mean*.

Perlu dilakukan pengujian *Dickey Fuller* kembali untuk data *differencing* 1, hasil ditampilkan pada Tabel 4.18. *syntax* pada Lampiran T2 menghasilkan pada Lampiran U2.

Tabel 4.18 Hasil Uji *Dickey Fuller* Setelah *Differencing*

Variabel	Estimasi Parameter	Standar d Error	t	<i>P-value</i>
$Z_t(3)$	-1.57275	0.11568	-13.60	<0,0001

Berdasarkan nilai t yang lebih besar dari 12,7062 dan *P-value* lebih kecil daripada α maka disimpulkan yaitu H_0 ditolak artinya data permintaan golongan darah B setelah *differencing* 1 telah stasioner dalam *mean*. *Syntax* terlampir pada Lampiran T3 dan *output* pada Lampiran U3.



Gambar 4.19 (a) Plot ACF dan (b) plot PACF Setelah *Differencing* Lag 1

Plot ACF yang tertera pada Gambar 4.19 menunjukkan bahwa plot *cut off* lag 1. Plot PACF pada Gambar 4.19 dan terlampir pada Lampiran S3 dan S4 menunjukkan bahwa terdapat lag 2 yang keluar batas sehingga model dugaan yang dapat diidentifikasi yaitu ARIMA (0,1,1) , (1,1,0), (1,1,1), (2,1,0), dan (2,1,1)

4.4.2 Estimasi dan Pengujian Parameter pada Permintaan Darah Golongan B

Estimasi dan pengujian parameter pada masing-masing model ARIMA dinyatakan dengan hipotesis sebagai berikut

Hipotesis :

$H_0 : \phi = 0$ atau $\theta = 0$ (Parameter AR atau MA tidak signifikan)

$H_1 : \phi \neq 0$ atau $\theta \neq 0$ (Parameter AR atau MA signifikan)

Pada pengujian ini digunakan taraf signifikan sebesar α yakni 0,05. Dengan daerah keputusan H_0 ditolak jika $|t|$ lebih besar dari $t_{\alpha/2, n-m}$; dan P -value kurang dari α . Berdasarkan *syntax* yang terlampir pada Lampirah V1 sampai V5 menghasilkan Lampiran W1 sampai W5 didapat nilai t hitung yang mengacu pada Persamaan 2.19, kemudian dilakukan estimasi dan pengujian parameter ditampilkan pada Tabel 4.12.

Tabel 4.19 Parameter pada Permintaan Darah Golongan B

Model ARIMA	Parameter	Estimasi	t	t-tabel	P -value	Keputusan
(0,1,1)	θ_1	0,65171	6,16	2,006	<0,0001	Sig.
(1,1,0)	ϕ_1	-	-4,96	2,006	<0,0001	Sig.
	θ_1	0,57275				
(1,1,1)	θ_1	0,51987	2,97	2,006	0,0045	Sig.
	ϕ_1	-	-1,32	2,006	0,1938	Tidak Sig.
(2,1,0)	ϕ_1	0,1272	0,91	2,006	0,3674	Tidak Sig.
	θ_1	0,69028	5,95	2,006	<0,0001	Sig.
(2,1,1)	ϕ_1	0,13886	0,87	2,006	0,3894	Tidak Sig.
	θ_1					

*Sig=signifikan

Tabel 4.19 menunjukkan bahwa dari kedua model dugaan yang diperoleh dari identifikasi lag-lag pada plot ACF dan plot PACF data permintaan golongan darah B. Model (1,1,1) dan (2,1,1) dilanjutkan ke uji asumsi residual.

4.4.3 Analisis Uji Asumsi Residual pada Permintaan Golongan Darah B

Pengujian untuk melihat residual telah *white noise* dapat dilakukan dengan menggunakan hipotesis dan statistik uji *Ljung-Box* sebagai berikut.

Hipotesis :

$$H_0 : \rho_{a_{t1}} = \rho_{a_{t2}} = \rho_{a_{t3}} = \dots = \rho_{a_k} = 0 \quad (\text{residual } \textit{white noise})$$

$$H_1 : \text{minimal ada satu } \rho_{a_k} \neq 0 \text{ untuk } k = 1, 2, \dots, L \\ (\text{residual tidak } \textit{white noise})$$

Taraf signifikan yang digunakan yaitu $\alpha = 0,05$ dan H_0 ditolak jika nilai χ^2 lebih besar dari $\chi^2_{(\alpha; k-p-q)}$ dan $P\text{-value}$ kurang dari $\alpha = 0,05$. Berdasarkan hasil Lampiran V3 dan V5 didapatkan nilai χ^2 sesuai dengan Persamaan 2.21.

Tabel 4.20 Asumsi *White Noise* pada Permintaan Darah Golongan B

Model ARIMA	χ^2	χ^2_{tabel}	$P\text{-value}$	Kesimpulan
(1,1,1)	1,70	12,59159	0,7905	<i>White noise</i>
	9,19	21,02607	0,5145	<i>White noise</i>
	10,28	28,8693	0,8518	<i>White noise</i>
	19,07	36,41503	0,6411	<i>White noise</i>
(2,1,1)	2,67	12,59159	0,6136	<i>White noise</i>
	9,90	21,02607	0,4492	<i>White noise</i>
	11,37	28,8693	0,7863	<i>White noise</i>
	21,49	36,41503	0,4906	<i>White noise</i>

Hasil pengujian asumsi *white noise* dapat dilihat pada Tabel 4.20. Model ARIMA yang tertera pada Tabel 4.20 dapat diketahui bahwa model kedua yang memenuhi asumsi *white noise* karena nilai $p\text{-value}$ yang dihasilkan lebih besar dari 0,05. Asumsi selanjutnya yang harus dipenuhi adalah residual harus berdistribusi normal, hal ini dapat diketahui dengan menggunakan

uji *kolmogorov smirnov*. Berikut adalah hipotesis yang digunakan dalam pengujian ini.

Hipotesis :

$H_0 : F_n(a_i) = F_0(a_i)$ (Residual berdistribusi normal)

$H_1 : F_n(a_i) \neq F_0(a_i)$ (Residual tidak berdistribusi normal)

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha = 0,05$. dengan daerah keputusan H_0 ditolak jika D_{hitung} lebih besar dari D_{tabel} selain itu juga bisa dilihat dari nilai P_{value} kurang dari $\alpha = 0,05$. Berdasarkan hasil pada Lampiran W3 dan W5 didapatkan nilai D_{hitung} sesuai dengan Persamaan 2.22. Hasil pengujian asumsi residual berdistribusi normal dengan menggunakan uji *Kolomogorov Smirnov* dapat dilihat pada Tabel 4.21

Tabel 4.21 Asumsi Distribusi Normal pada Permintaan Darah Golongan B

Model ARIMA	D_{hitung}	D_{Tabel}	P_{-value}	Keputusan
(1,1,1)	0,06676	0,1848	>0,1500	Berdistribusi Normal
(2,1,1)	0,07939	0,1848	>0,1500	Berdistribusi Normal

Tabel 4.21 menunjukkan bahwa pada kedua model ARIMA memenuhi asumsi distribusi normal.

4.4.4 Pemilihan Model Terbaik pada Permintaan Golongan Darah B

Model ARIMA yang didapatkan selanjutnya akan dipilih untuk digunakan sebagai model yang dapat memprediksi permintaan golongan darah B satu tahun kedepan selama tahun 2017. Dimana penghitungan manual ada pada Lampiran X1 sampai X4

Tabel 4.22 Pemilihan Model Terbaik Permintaan Golongan Darah B

Model ARIMA	<i>Outsample</i>		<i>Insample</i>	
	sMAPE	RMSE	AIC	SBC
(1,1,1)	0,087251	32,246	532,2215	536,1621
(2,1,1)	0,088372	31,992	533,3074	537,248

Tabel 4.22 menunjukkan bahwa model yang memenuhi 4 kriteria pemilihan model adalah ARIMA (2,1,1). Dari model terbaik, didapatkan nilai peramalan untuk 12 bulan kedepan. Secara umum model ARIMA (2,1,1) adalah sebagai berikut.

$$\begin{aligned}
\phi_2(B)(1-B)^1 \dot{Z}_t &= \theta_1(B)a_t \\
(\phi_2 B)(1-B)^1 \dot{Z}_t &= \theta_1(B)a_t \\
(1-\phi_2 B)(1-B)^1 \dot{Z}_t &= (1-\theta_1 B)a_t \\
(1-B-\phi_2 B+\phi_2 B^2) \dot{Z}_t &= a_t - \theta_1 a_{t-1} \\
\dot{Z}_t - \dot{Z}_{t-1} - \phi_2 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} &= a_t - \theta_1 a_{t-1} \\
\dot{Z}_t &= \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-1} - \phi_2 \dot{Z}_{t-2} + a_t - \theta_1 a_{t-1} \\
Z_t - \mu &= Z_{t-1} - \mu + \phi_2 (Z_{t-1} - \mu) - \phi_2 (Z_{t-2} - \mu) + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + \phi_2 Z_{t-1} - \phi_2 \mu - \phi_2 Z_{t-2} + \phi_2 \mu + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + \phi_2 Z_{t-1} - \phi_2 Z_{t-2} + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + 0,13886Z_{t-1} - 0,13886Z_{t-2} + a_t - 0,69028a_{t-1}
\end{aligned}$$

Berdasarkan model matematis diatas diketahui bahwa permintaan darah B dipengaruhi oleh permintaan 1 dan 2 bulan sebelumnya serta dipengaruhi oleh kesalahan peramalan pada 1 bulan yang lalu. Berdasarkan nilai ramalan yang terlampir pada Lampiran AF3darah B rata-rata permintaannya 298 kantong dengan batas bawah dan batas atas yang bervariasi dimana nilai nya lebih besar dibanding nilai minimum dan nilai maksimum data permintaan 2012-2016. Berikut adalah ramalan permintaan dan batas-batasnya.

Tabel 4.23 Hasil Prediksi pada Permintaan Darah Golongan B Tahun 2017

Bulan	Batas Bawah	Nilai Prediksi	Batas Atas
Januari	201	298	394
Februari	198	298	397
Maret	195	298	400
April	192	298	403
Mei	189	298	407
Juni	186	298	410
Juli	183	298	412
Agustus	180	298	415

Bulan	Batas Bawah	Nilai Prediksi	Batas Atas
September	177	298	418
Oktober	174	298	421
November	172	298	423
Desember	169	298	426


Tabel 4.23 menunjukkan bahwa hasil prediksi permintaan golongan darah B pada tahun 2017 dimana sepanjang tahun perlu persediaan kantong golongan darah B sebanyak 298 kantong.

4.5 Pemodelan Permintaan Golongan Darah AB

Pemodelan yang dilakukan keempat atau terakhir yaitu permintaan golongan darah AB.

4.5.1 Identifikasi Model pada Permintaan Golongan Darah AB


Time series plot dari data jumlah permintaan golongan darah AB disajikan dalam Gambar 4.20 sebagai berikut.



Gambar 4.20 Time Series Plot pada Permintaan Darah Golongan AB

Gambar 4.20 menunjukkan bahwa data jumlah permintaan golongan darah AB mulai Januari 2012 sampai bulan Desember 2016 tidak stasioner dalam *mean*.


Grafik *Box-Cox Transformation* dalam Gambar 4.21.



Gambar 4.21 Plot *Box-Cox* pada Permintaan Darah Golongan AB

Plot *Box-Cox* pada Gambar 4.21 menginformasikan bahwa permintaan darah golongan AB di Nganjuk sudah stasioner dalam varians. Hal tersebut dapat diketahui melalui nilai λ yang bernilai 1 serta nilai *Upper CL* lebih besar dari 1. Selanjutnya dapat dilakukan pengecekan stasioner terhadap *mean* dengan menggunakan plot ACF.

Plot ACF pada data permintaan darah golongan AB menunjukkan bahwa data tersebut tidak stasioner dalam *mean*. Dimana ACF terlampaui pada Lampiran Y1 serta PACF pada Lampiran Z1.



Gambar 4.22 Plot ACF pada Data Permintaan Darah Golongan AB

Gambar 4.22 menunjukkan bahwa pola plot secara visual turun lambat (*dies down*) . Hal tersebut mengartikan bahwa data tidak stasioner terhadap *mean*, sehingga harus dilakukan *differencing* pada data permintaan darah golongan AB.

Perlu dilakukan pemeriksaan stasioneritas terhadap *mean* dengan pengujian *Dickey Fuller* untuk hasil yang lebih akurat.

Hipotesis :

H_0 : Data tidak stasioner dalam *mean* ($\delta = 0$)

H_1 : Data stasioner dalam *mean* ($\delta \neq 0$)

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha=0,05$. dengan daerah keputusan H_0 ditolak jika $t > t_{\alpha,df}$; $t_{0,05,1}=12,7062$ dan P_{value} kurang dari $\alpha = 0,05$. Berdasarkan hasil pengujian pada Lampiran AB1 didapatkan nilai t dari Persamaan 2.11 yang dapat ditampilkan pada Tabel 4.24

Tabel 4.24 Hasil Uji *Dickey Fuller* Sebelum *Differencing*

Variabel	Estimasi Parameter	Standar d Error	t	P-value
$Z_t(4)$	-0.05048	-0.05048	-1.03	0.3084


Tabel 4.24 menunjukkan bahwa hasil pengujian stasioneritas dengan *Dickey Fuller* didapatkan nilai statistik uji t sebesar -1,03 kurang dari nilai $t_{0,05,1}$ yaitu 12,7062 dan nilai P_{value} sebesar 0,3084 lebih besar daripada nilai signifikan. *Syntax* dan Output pengujian *Dickey Fuller* terlampir pada Lampiran AA1 dan AB1. Berdasarkan dari dua pernyataan sebelumnya, dapat diperoleh keputusan yaitu gagal tolak H_0 dan dapat disimpulkan bahwa data permintaan golongan darah AB tidak stasioner dalam *mean*. Perlu dilakukan *differencing* untuk mengatasi ketidakstasioneran dalam *mean*.

Pengujian *Dickey Fuller* kembali untuk data *differencing* 1, hasil ditampilkan pada Tabel 4.25

Tabel 4.25 Hasil Uji *Dickey Fuller* Setelah *Differencing*

Variabel	Estimasi Parameter	Standar d Error	t	P-value
$Z_t(4)$	-1.47134	0.12627	-11.65	<0,0001

Berdasarkan nilai t yang lebih besar dari 12,7062 dan P -value lebih kecil daripada $\alpha = 0,05$ maka disimpulkan yaitu H_0 ditolak artinya data permintaan golongan d *Syntax* dan Output pengujian *Dickey Fuller* terlampir pada Lampiran AA2 dan AB2 setelah *differencing* 1 telah stasioner dalam *mean*.



Gambar 4.23 (a) Plot ACF dan (b) plot PACF Setelah *Differencing* Lag 1

Plot ACF yang tertera pada Gambar 4.23 menunjukkan bahwa plot *cut off* lag 1 dimana terlampir pada Lampiran Y2. Plot PACF pada Gambar 4.19 dan pada Lampiran Z4 menunjukkan bahwa terdapat lag 3 yang keluar batas yaitu lag 1,2,3 sehingga

model dugaan yang dapat diidentifikasi yaitu ARIMA (0,1,1), ARIMA (3,1,0).

4.5.2 Estimasi dan Pengujian Parameter pada Permintaan Darah Golongan AB

Estimasi dan pengujian parameter pada masing-masing model ARIMA dinyatakan dengan hipotesis sebagai berikut

Hipotesis :

$H_0 : \phi = 0$ atau $\theta = 0$ (Parameter AR atau MA tidak signifikan)

$H_1 : \phi \neq 0$ atau $\theta \neq 0$ (Parameter AR atau MA signifikan)

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha=0,05$. dengan daerah keputusan H_0 ditolak jika $|t| > t_{\alpha/2, n-m}$; dan $P\text{-value}$ kurang dari $\alpha = 0,05$. Berdasarkan *syntax* terlampir pada Lampiran AC1 dan AC2 yang menghasilkan Lampiran AD1 dan AD2 didapat nilai t hitung yang bengacu pada Persamaan 2.19, kemudian dilakukan estimasi dan pengujian parameter ditampilkan pada Tabel 4.26.

Tabel 4.26 Parameter pada Permintaan Darah Golongan AB

Model ARIMA	Parameter	Estimasi	t	t-tabel	P-value	Keputusan
(0,1,1)	θ_1	0.83346	10.61	2,006	<0.0001	Sig.
	ϕ_1	- 0.81766	-6.00	2,008	<.0001	Sig.
(3,1,0)	ϕ_2	- 0.66971	-4,44	2,008	<.0001	Sig.
	ϕ_3	- 0.32030	-2.30	2,008	0.0257	Sig.

*Sig=signifikan

Tabel 4.26 menunjukkan bahwa dari kedua model dugaan yang diperoleh dari identifikasi lag-lag pada plot ACF dan plot PACF data permintaan golongan darah AB, model dugaan telah signifikan karena nilai *p-value* dari setiap parameter pada kedua model kurang daari 0,05. Model yang telah signifikan adalah

ARIMA (0,1,1) dan ARIMA (3,1,0).Maka kedua model dapat melanjutkan uji asumsi.

4.5.3 Analisis Uji Asumsi Residual pada Permintaan Golongan Darah AB

Estimasi dan pengujian parameter pada masing-masing model ARIMA dinyatakan dengan hipotesis sebagai berikut

Hipotesis :

$H_0 : \phi = 0$ atau $\theta = 0$ (Parameter AR atau MA tidak signifikan)

$H_1 : \phi \neq 0$ atau $\theta \neq 0$ (Parameter AR atau MA signifikan)

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha=0,05$. dengan daerah keputusan H_0 ditolak jika $|t| > t_{\alpha/2, n-m}$; dan P_{value} kurang dari $\alpha = 0,05$. Berdasarkan hasil Lampiran AD1 dan AD2 didapat nilai t hitung yang bengacu pada Persamaan 2.19, kemudian dilakukan estimasi dan pengujian parameter ditampilkan pada Tabel 4.27.

Tabel 4.27 Asumsi *White Noise* pada Permintaan Darah Golongan AB

Model ARIMA	χ^2	χ^2_{tabel}	$P-value$	Kesimpulan
(0,1,1)	4,81	11,0705	0.4390	<i>White noise</i>
	8,78	19,67514	0.6465	<i>White noise</i>
	13,02	27,58711	0.7350	<i>White noise</i>
	17,25	35,17246	0.7966	<i>White noise</i>
(3,1,0)	7.24	12,59159	0.0646	<i>White noise</i>
	10.21	21,02607	0.3334	<i>White noise</i>
	15.39	28,8693	0.4236	<i>White noise</i>
	19.54	36,41503	0.5503	<i>White noise</i>

Hasil pengujian asumsi *white noise* dapat dilihat pada Tabel 4.27. Model ARIMA yang tertera pada Tabel 4.26 dapat diketahui bahwa model kedua yang memenuhi asumsi *white noise* karena nilai $p-value$ yang dihasilkan lebih besar dari 0,05. Asumsi selanjutnya yang harus dipenuhi adalah residual harus

berdistribusi normal, hal ini dapat diketahui dengan menggunakan uji *kolmogorov smirnov*. Berikut adalah hipotesis yang digunakan dalam pengujian ini.

Hipotesis :

$H_0 : F_n(a_t) = F_0(a_t)$ (Residual berdistribusi normal)

$H_1 : F_n(a_t) \neq F_0(a_t)$ (Residual tidak berdistribusi normal)

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha = 0,05$. dengan daerah keputusan H_0 ditolak jika D_{hitung} lebih besar dari D_{tabel} selain itu juga bisa dilihat dari nilai P_{value} kurang dari $\alpha = 0,05$. Didapatkan nilai D_{hitung} sesuai dengan Persamaan 2.22. Hasil pengujian asumsi residual berdistribusi normal dengan menggunakan uji *Kolmogorov Smirnov* dapat dilihat pada Tabel 4.28.

Tabel 4.28 Asumsi Distribusi Normal pada Permintaan Darah Golongan AB

Model ARIMA	D_{hitung}	D_{Tabel}	P_{value}	Keputusan
(0,1,1)	0.064308	0,1848	>0,1500	Berdistribusi Normal
(3,1,0)	0.068142	0,1848	>0,1500	Berdistribusi Normal

Tabel 4.28 menunjukkan bahwa pada kedua model ARIMA memenuhi asumsi distribusi normal.

4.5.4 Pemilihan Model Terbaik pada Permintaan Golongan Darah AB

Model ARIMA yang didapatkan selanjutnya akan dipilih untuk digunakan sebagai model yang dapat memprediksi permintaan golongan darah AB satu tahun kedepan selama tahun 2017. Penghitungan manual terlampir pada Lampiran AE1sampai AE3.

Tabel 4.29 Pemilihan Model Terbaik Permintaan Golongan Darah AB

Model	<i>Outsample</i>		<i>Insample</i>	
ARIMA	sMAPE	RMSE	AIC	SBC
(0,1,1)	1,3385	19,416	431.5268	433.4971
(3,1,0)	1,348	20,363	437.4779	443.3888

Dari model terbaik, didapatkan nilai peramalan untuk 12 bulan kedepan. Secara umum model ARIMA (0,1,1) adalah sebagai berikut.

$$\begin{aligned}
(1-B)^1 \dot{Z}_t &= \theta_1(B)a_t \\
\dot{Z}_t - \dot{Z}_{t-1} &= (1-\theta_1 B)a_t \\
\dot{Z}_t - \dot{Z}_{t-1} &= a_t - \theta_1 a_{t-1} \\
\dot{Z}_t &= \dot{Z}_{t-1} + a_t - \theta_1 a_{t-1} \\
Z_t - \mu &= Z_{t-1} - \mu + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + a_t - \theta_1 a_{t-1} \\
Z_t &= Z_{t-1} + a_t - 0,88346a_{t-1}
\end{aligned}$$

Berdasarkan model matematis diatas diketahui bahwa permintaan darah AB dipengaruhi oleh permintaan 1 bulan sebelumnya serta dipengaruhi oleh kesalahan peramalan pada 1 bulan yang lalu. *Output* peramalan terlampir pada Lampiran AF4.

Tabel 4.30 Hasil Prediksi pada Permintaan Darah Golongan AB Tahun 2017

Bulan	Batas Bawah	Nilai Prediksi	Batas Atas
Januari	36	65	95
Februari	35	65	95
Maret	35	65	96
April	35	65	96
Mei	34	65	96
Juni	34	65	97
Juli	34	65	97
Agustus	33	65	97
September	33	65	98
Oktober	32	65	98
November	32	65	99
Desember	32	65	99

Tabel 4.30 menunjukkan bahwa hasil prediksi permintaan golongan darah AB pada tahun 2017 dimana sepanjang tahun perlu persediaan kantong golongan darah AB sebanyak 63 kantong. Berdasarkan hasil peramalan bahwa di prediksi

permintaan darah AB pada tahun 2017 meningkat dibanding permintaan tahun 2012-2016.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, didapatkan sebuah kesimpulan bahwa model terbaik permintaan golongan darah O, golongan darah A, golongan darah B dan golongan darah AB

1. Golongan darah O merupakan golongan darah terbanyak dibutuhkan dan berdasar hasil peramalan di prediksi rata-rata kebutuhan darah O meningkat dari 312 kantong menjadi 405 kantong tiap bulan. Permintaan darah A meningkat dari 177 kantong menjadi 242 kantong tiap bulan, darah B menjadi 298 kantong dan darah AB 65 kantong.
2. Model terpilih peramalan permintaan golongan darah O yaitu ARIMA (0,1,1)(0,1,0)¹²
$$Z_t = Z_{t-1} + 0,11540Z_{t-12} - 0,11540Z_{t-13} + a_t - 0,65113a_{t-1}$$
3. Model terpilih peramalan permintaan golongan darah A yaitu ARIMA ([1,3,4],1,0)
$$Z_t = Z_{t-1} + Z_{t-12} - Z_{t-13} + a_t - 0,84448a_{t-1}$$
4. Model terpilih peramalan permintaan golongan darah B yaitu ARIMA (2,1,1)
$$Z_t = Z_{t-1} + 0,13886Z_{t-1} - 0,13886Z_{t-2} + a_t - 0,69028a_{t-1}$$
5. Model terpilih peramalan permintan golongan darah AB yaitu ARIMA (0,1,1)
$$Z_t = Z_{t-1} + a_t - 0,88346a_{t-1}$$

5.2 Saran

Saran untuk UDD PMI Kabupaten Nganjuk :

1. Tidak menyimpan persediaan darah maksimal untuk menghindari darah *expired* sehingga harus dibuang.
2. Selalu melakukan penyimpanan jumlah minimal yang telah diramalkan untuk menghindari darah tidak terpakai.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis with Application in R*. New York: Springer.
- Daniel, W. W. (1989). In *Statistika Non Parametrik*. Diterjemahkan oleh: Alex Tri Kantjono W. Jakarta: PT. Gramedia Pustaka Utama.
- Evelyn C.Pearce. 2008. Anatomi dan fisiologi untuk para medis. Jakarta: PT Gramedia.
- Gooijer, J. D., & Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting* vol. 22 no. 443-473.
- Gujarati, D. N., & Porter, D. C. 2012. *Dasar-dasar Ekonometrika Edisi 5 buku 2*. Raden Carlos Mangunsong (trans). Jakarta : Salemba Empat
- Makridakis, S., Wheelwright, S. C., & McGEE, V. E. (1999). Metode dan Aplikasi Peramalan Jilid 1. Diterjemahkan oleh: Ir. Hari Suminto. Jakarta: Binarupa Aksara Publisher.
- Wei, W. W. (2006). *Time Series Analysis Univariat and Multivariat Methods*. Canada: Addison Wesley Publishing Company.

LAMPIRAN

Lampiran A Surat Pernyataan Keaslian Data

SURAT PERNYATAAN

Saya yang bertanda tangan dibawah ini, mahasiswa Departemen Statistika Bisnis
Fakultas Vokasi ITS :

Nama : Dea Trishnanti
NRP : 1314 030 044

Menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data
sekunder yang diambil dari ~~Penelitian/Buku/Tugas Akhir/Thesis/Publikasi *~~ yaitu

Sumber : Buku Pasien dan Laporan Kegiatan Tahun 2012-2016
Keterangan : Data Permintaan Darah Golongan O, A, B dan AB


Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data,
maka saya siap menerima sanksi sesuai dengan peraturan yang berlaku.

Mengetahui,
Koor. TU UTD PMI Kab. Nganjuk,




(Herin Purnawati, S.Pd)

Surabaya, 5-Mei-2017
Yang Membuat Pernyataan,



(Dea Trishnanti)
NRP. 1314 030 044

Mengetahui,
Dosen Pembimbing Tugas Akhir,



(Dr. Wahyu Wibowo, S.Si., M.Si)
NIP. 19740328 199802 1 001

Lampiran B Surat Keterangan Pengambilan Data Permintaan Darah oleh UDD PMI Kabupaten Nganjuk



SURAT KETERANGAN

No. 234/UTD/ADM/VII/2017

1. Yang bertanda tangan dibawah ini :

- a. Nama : Dr. DIDIK JAMA'ADI
- b. Jabatan : Kepala UTD PMI Kabupaten Nganjuk

Dengan ini menerangkan bahwa :

- a. Nama : Dea Trishnanti
- b. Pekerjaan : Mahasiswa Institut Teknologi Sepuluh Nopember
- c. Tema Penelitian : Peramalan Permintaan Darah Di Nganjuk
(Studi Kasus : UDD PMI Kabupaten Nganjuk)

2. Yang bersangkutan telah melakukan Penelitian di Kantor Unit Transfusi Darah PMI Kabupaten Nganjuk Jl. Mayjend Sungkono No. 10 Nganjuk Pada Permintaan Darah Golongan O, A, B dan AB Selama Pebruari s.d April 2017.

3. Demikian Surat Keterangan ini untuk dapat dipergunakan sebagaimana mestinya.

Nganjuk, 12 Juli 2017

Unit Transfusi Darah

PALANG MERAH INDONESIA

Kab. Nganjuk

Kepala,


Dr. DIDIK JAMA'ADI

Lampiran C1 Data Permintaan Darah (Kantong)

Tahun	Bulan	Gol. O	Gol. A	Gol. B	Gol. AB
2012	Januari	299	140	216	46
	Februari	240	136	183	34
	Maret	231	172	185	41
	April	229	107	203	49
	Mei	249	133	187	41
	Juni	208	97	151	33
	Juli	253	144	225	53
	Agustus	129	56	105	16
	September	288	162	191	60
	Oktober	303	191	208	45
	Nopember	210	134	182	47
	Desember	278	173	199	51
2013	Januari	187	143	167	45
	Februari	186	90	143	22
	Maret	251	161	185	37
	April	217	110	151	42
	Mei	198	135	170	27
	Juni	187	108	125	36
	Juli	176	94	139	32
	Agustus	143	100	106	21

Lampiran C1 Data Permintaan Darah (Kantong) (*Lanjutan*)

Tahun	Bulan	Gol. O	Gol. A	Gol. B	Gol. AB
2013	September	302	169	199	64
	Oktober	226	137	196	62
	Nopember	251	112	203	36
	Desember	192	115	140	28
2014	Januari	291	182	171	42
	Februari	275	139	255	54
	Maret	255	151	185	58
	April	295	155	225	35
	Mei	270	176	238	56
	Juni	305	159	256	59
	Juli	294	165	176	51
	Agustus	340	148	278	42
	September	349	196	231	73
	Oktober	379	239	260	57
	Nopember	329	209	285	74
	Desember	366	228	263	67
2015	Januari	396	185	285	61
	Februari	383	154	279	40
	Maret	425	183	262	55
	April	310	264	298	59

Lampiran C1 Data Permintaan Darah (Kantong) (*Lanjutan*)

Tahun	Bulan	Gol. O	Gol. A	Gol. B	Gol. AB
2015	Mei	381	225	316	82
	Juni	309	216	281	55
	Juli	343	132	225	49
	Agustus	392	275	291	59
	September	454	220	266	69
	Oktober	346	194	312	68
	Nopember	378	221	327	46
	Desember	384	154	323	63
2016	Januari	387	297	346	92
	Februari	400	194	307	49
	Maret	415	266	305	62
	April	409	207	284	78
	Mei	374	254	321	50
	Juni	410	236	274	78
	Juli	436	234	344	79
	Agustus	497	303	314	51
	September	494	263	285	71
	Oktober	392	238	340	105
	Nopember	420	188	341	60
	Desember	402	241	293	58

Lampiran D *Output Minitab Autocorrelation Function Golda O*
Lampiran D1 *Output Minitab Autocorrelation Function sebelum differencing*

Autocorrelation Function: O

Lag	ACF	T	LBQ
1	0,720449	5,29	29,62
2	0,740049	3,81	61,46
3	0,679805	2,82	88,87
4	0,642774	2,34	113,85
5	0,631287	2,10	138,45
6	0,608613	1,88	161,78
7	0,521123	1,51	179,26
8	0,440870	1,23	192,03
9	0,457746	1,24	206,12
10	0,354084	0,93	214,73
11	0,398704	1,03	225,91
12	0,313236	0,80	232,98
13	0,264223	0,66	238,12
14	0,185888	0,46	240,74
15	0,148256	0,37	242,44
16	0,143416	0,36	244,08
17	0,009027	0,02	244,08
18	-0,012220	-0,03	244,10
19	-0,123368	-0,31	245,41
20	-0,120439	-0,30	246,70
21	-0,197976	-0,49	250,29
22	-0,193213	-0,47	253,82
23	-0,239523	-0,59	259,42
24	-0,252730	-0,61	265,86
25	-0,337184	-0,81	277,71
26	-0,337310	-0,80	290,00
27	-0,328277	-0,77	302,07
28	-0,369996	-0,86	317,99
29	-0,339891	-0,78	331,97
30	-0,402175	-0,91	352,35
31	-0,416308	-0,93	375,13
32	-0,375135	-0,83	394,48
33	-0,366442	-0,80	413,81
34	-0,359196	-0,77	433,32
35	-0,312387	-0,66	448,85
36	-0,294713	-0,62	463,44

Lampiran D1 *Output Minitab Autocorrelation Function sebelum differencing (lanjutan)*

37	-0,301516	-0,63	479,62
38	-0,231569	-0,48	489,75
39	-0,231053	-0,48	500,51
40	-0,211652	-0,44	510,19
41	-0,206617	-0,42	520,12
42	-0,176017	-0,36	527,93
43	-0,185329	-0,38	537,37
44	-0,147617	-0,30	543,96
45	-0,145727	-0,30	551,09
46	-0,160064	-0,33	560,78
47	-0,106527	-0,22	565,68
48	-0,100339	-0,20	570,76
49	-0,070923	-0,14	573,80
50	-0,054614	-0,11	576,05

Lampiran D2 *Output Minitab Autocorrelation Function sesudah differencing*

MTB > ACF C2;
SUBC> Lags 50.

Autocorrelation Function: C2

Lag	ACF	T	LBQ
1	-0,551705	-4,02	17,06
2	0,129292	0,74	18,02
3	-0,050323	-0,29	18,17
4	-0,041643	-0,24	18,27
5	0,027528	0,16	18,32
6	0,123970	0,70	19,27
7	-0,012321	-0,07	19,28
8	-0,168229	-0,94	21,11
9	0,162254	0,90	22,86
10	-0,247405	-1,35	27,00
11	0,277708	1,46	32,36
12	-0,049920	-0,25	32,53
13	0,009287	0,05	32,54
14	-0,035703	-0,18	32,64
15	-0,136049	-0,69	34,06
16	0,271481	1,36	39,86
17	-0,227332	-1,10	44,05

Lampiran D2 *Output Minitab Autocorrelation Function sesudah differencing (lanjutan)*

18	0,188032	0,89	46,99
19	-0,197989	-0,92	50,35
20	0,120806	0,55	51,64
21	-0,140484	-0,64	53,44
22	0,101587	0,46	54,41
23	-0,036380	-0,16	54,54
24	0,128201	0,58	56,19
25	-0,140338	-0,63	58,24
26	-0,033861	-0,15	58,36
27	0,121306	0,54	60,01
28	-0,150368	-0,67	62,65
29	0,166249	0,73	66,01
30	-0,030738	-0,13	66,13
31	-0,142231	-0,62	68,81
32	0,078144	0,34	69,66
33	-0,044113	-0,19	69,94
34	0,023759	0,10	70,03
35	0,036555	0,16	70,24
36	0,041413	0,18	70,54
37	-0,152377	-0,65	74,77
38	0,122411	0,52	77,68
39	-0,056531	-0,24	78,34
40	0,068278	0,29	79,39
41	-0,048639	-0,21	79,96
42	0,019915	0,08	80,07
43	-0,047472	-0,20	80,73
44	0,011598	0,05	80,77
45	0,040636	0,17	81,37
46	-0,030581	-0,13	81,76
47	0,014683	0,06	81,87
48	-0,015902	-0,07	82,01
49	0,000331	0,00	82,01
50	0,004205	0,02	82,03

Lampiran E1 *Output Minitab Partial Autocorrelation Function sebelum differencing*

```
MTB > PACF 'O';
SUBC>    Lags 50.
```

Partial Autocorrelation Function: O

Lag	PACF	T
1	0,720449	5,29
2	0,459508	3,38
3	0,159674	1,17
4	0,051001	0,37
5	0,092400	0,68
6	0,071710	0,53
7	-0,149613	-1,10
8	-0,224735	-1,65
9	0,097914	0,72
10	-0,098031	-0,72
11	0,115656	0,85
12	-0,045118	-0,33
13	-0,069555	-0,51
14	-0,146302	-1,08
15	-0,089978	-0,66
16	0,095219	0,70
17	-0,289955	-2,13
18	-0,127051	-0,93
19	-0,079619	-0,59
20	0,071538	0,53
21	-0,061379	-0,45
22	0,003173	0,02
23	0,128341	0,94
24	0,078712	0,58
25	-0,254766	-1,87
26	0,013985	0,10
27	0,050226	0,37
28	-0,012980	-0,10
29	0,008285	0,06

Lampiran E1 *Output Minitab Partial Autocorrelation Function sebelum differencing (lanjutan)*

30	0,047495	0,35
31	-0,058795	-0,43
32	0,082583	0,61
33	0,114824	0,84
34	0,035672	0,26
35	-0,004820	-0,04
36	0,075351	0,55
37	0,033611	0,25
38	-0,072970	-0,54
39	-0,104497	-0,77
40	-0,076408	-0,56
41	0,008235	0,06
42	-0,021692	-0,16
43	-0,104853	-0,77
44	-0,062209	-0,46
45	-0,059663	-0,44
46	-0,113405	-0,83
47	0,043659	0,32
48	-0,047139	-0,35
49	0,003277	0,02
50	-0,021090	-0,15

Lampiran E2 *Output Minitab Partial Autocorrelation Function sesudah differencing*

```
MTB > PACF C2;
SUBC>    Lags 50.
```

Partial Autocorrelation Function: C2

Lag	PACF	T
1	-0,551705	-4,02
2	-0,251697	-1,83
3	-0,153328	-1,12
4	-0,183417	-1,34
5	-0,145371	-1,06
6	0,110319	0,80
7	0,232386	1,69
8	-0,059056	-0,43

Lampiran E2 *Output Minitab Partial Autocorrelation Function*
 sesudah *differencing* (lanjutan)

9	0,035807	0,26
10	-0,225796	-1,64
11	-0,002450	-0,02
12	0,112539	0,82
13	0,146755	1,07
14	0,142945	1,04
15	-0,147062	-1,07
16	0,203907	1,48
17	-0,046109	-0,34
18	-0,065430	-0,48
19	-0,178309	-1,30
20	-0,057437	-0,42
21	-0,042507	-0,31
22	-0,136960	-1,00
23	-0,147882	-1,08
24	0,200357	1,46
25	0,001251	0,01
26	-0,002820	-0,02
27	-0,043482	-0,32
28	-0,112243	-0,82
29	-0,054980	-0,40
30	0,101598	0,74
31	-0,044979	-0,33
32	-0,080359	-0,59
33	-0,043244	-0,31
34	0,039007	0,28
35	-0,032164	-0,23
36	-0,064267	-0,47
37	0,001516	0,01
38	0,063800	0,46
39	0,090448	0,66
40	-0,028594	-0,21
41	-0,074226	-0,54
42	-0,007366	-0,05
43	0,007213	0,05
44	0,032050	0,23
45	0,008888	0,06
46	-0,052430	-0,38
47	0,026075	0,19
48	-0,023366	-0,17
49	-0,013296	-0,10
50	-0,099490	-0,72

Lampiran E3 *Output Minitab Autocorrelation Function sesudah differencing 12*

```
MTB > ACF 'Diff12';
SUBC>    Lags 50.
```

Autocorrelation Function: Diff12

Lag	ACF	T	LBQ
1	-0,692708	-4,44	21,15
2	0,344506	1,58	26,51
3	-0,107037	-0,46	27,05
4	-0,077350	-0,33	27,33
5	0,175822	0,75	28,84
6	-0,144562	-0,61	29,90
7	0,198878	0,83	31,95
8	-0,281029	-1,16	36,17
9	0,289979	1,16	40,80
10	-0,349187	-1,35	47,73
11	0,457517	1,70	60,04
12	-0,472565	-1,64	73,61
13	0,328852	1,07	80,42
14	-0,138877	-0,44	81,68
15	-0,113862	-0,36	82,56
16	0,284969	0,90	88,29
17	-0,316381	-0,98	95,64
18	0,229025	0,69	99,66
19	-0,163030	-0,49	101,79
20	0,126417	0,38	103,13
21	-0,135607	-0,40	104,75
22	0,119328	0,35	106,07
23	-0,117159	-0,34	107,42
24	0,126150	0,37	109,07
25	-0,073978	-0,22	109,67
26	-0,032235	-0,09	109,79
27	0,118717	0,35	111,57
28	-0,202234	-0,59	117,12
29	0,194848	0,56	122,69
30	-0,096944	-0,28	124,20
31	0,028867	0,08	124,35
32	0,008915	0,03	124,36
33	-0,053280	-0,15	124,99
34	0,050995	0,15	125,64
35	-0,044016	-0,13	126,21

Lampiran E3 *Output Minitab Autocorrelation Function sesudah differencing 12 (lanjutan)*

36	0,008613	0,02	126,24
37	0,017438	0,05	126,37
38	-0,020758	-0,06	126,62
39	0,004163	0,01	126,64
40	0,018803	0,05	127,26

Lampiran E4 *Output Minitab Partial Autocorrelation Function sesudah differencing 12*

```
MTB > PACF 'Diff12';
SUBC>    Lags 50.
```

Partial Autocorrelation Function: Diff12

Lag	PACF	T
1	-0,692708	-4,44
2	-0,260188	-1,67
3	0,027762	0,18
4	-0,143418	-0,92
5	0,029818	0,19
6	0,078676	0,50
7	0,263601	1,69
8	-0,108916	-0,70
9	0,041487	0,27
10	-0,261263	-1,67
11	0,278569	1,78
12	-0,210531	-1,35
13	-0,031687	-0,20
14	-0,035764	-0,23
15	-0,079952	-0,51
16	-0,053437	-0,34
17	0,032850	0,21
18	-0,172632	-1,11
19	0,102535	0,66
20	-0,053782	-0,34
21	0,030434	0,19
22	-0,202217	-1,29
23	0,061022	0,39
24	0,013329	0,09
25	0,098594	0,63

Lampiran E4 *Output Minitab Partial Autocorrelation Function*
sesudah *differencing* 12 (lanjutan)

26	-0,120172	-0,77
27	0,001789	0,01
28	-0,090194	-0,58
29	-0,030867	-0,20
30	-0,092543	-0,59
31	0,099419	0,64
32	-0,018492	-0,12
33	-0,006449	-0,04
34	-0,064120	-0,41
35	-0,093539	-0,60
36	-0,159320	-1,02
37	0,006190	0,04
38	-0,041348	-0,26
39	0,070311	0,45
40	-0,047659	-0,31

Lampiran F1 Syntax SAS Pengujian *Dickey Fuller* sebelum
diferencing

```
data goldao;
input y;
datalines;
299
240
231
229
249
.
.
.
400
415
409
374
410
;
data goldao;
set goldao;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldao;
model yd=y1/noint;
run;
```

Lampiran F2 Syntax SAS Pengujian *Dickey Fuller* sesudah
diferencing

```
data goldao;
input y;
datalines;
*
-59
-9
-2
20
.
.
.
13
15
-6
-35
36
;
data goldao;
set goldao;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldao;
model yd=y1/noint;
run;
```

Lampiran F3 Syntax SAS Pengujian *Dickey Fuller* sesudah *differencing* 12

```
data goldao;
input y;
datalines;
*
*
*
*
*
.
.
.
26
-27
109
-106
108
;
data goldao;
set goldao;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldao;
model yd=y1/noint;
run;
```

Lampiran G1 *Output SAS Hasil Pengujian Dickey Fuller Sebelum Differencing*

Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	544.39816	544.39816	0.16	0.6950
Error	52	182163	3503.12696		
Uncorrected Total	53	182707			
Root MSE		59.18722	R-Square	0.0030	
Dependent Mean		2.09434	Adj R-Sq	-0.0162	
Coeff Var		2826.05643			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1	1	-0.01047	0.02656	-0.39	0.6950

Lampiran G2 *Output SAS Hasil Pengujian Dickey Fuller Sesudah Differencing*

Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	437736	437736	180.51	<.0001
Error	51	123675	2425.00137		
Uncorrected Total	52	561411			
Root MSE		49.24430	R-Square	0.7797	
Dependent Mean		1.82692	Adj R-Sq	0.7754	
Coeff Var		2695.47763			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1	1	-1.55337	0.11562	-13.44	<.0001

Lampiran H1 Syntax SAS Pengujian Model ARIMA (2,1,0)

```
data goldao;
input y;
datalines;
299
240
231
229
249
.
.
.
400
415
409
374
410
;
proc arima data=goldao;
identify var=y(1);
estimate
p=(1,2) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=12;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```


Lampiran H2 Syntax SAS Pengujian Model ARIMA (0,1,1)

```
data goldao;
input y;
datalines;
299
240
231
229
249
.
.
.
400
415
409
374
410
;
proc arima data=goldao;
identify var=y(1);
estimate
p=(0) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=12;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran H3 Syntax SAS Pengujian Model ARIMA (0,1,1)(1,0,0)¹²

```
data goldao;
input y;
datalines;
299
240
231
229
249
.
.
.
400
415
409
374
410
;
proc arima data=goldao;
identify var=y(1);
estimate
p=(0)(12) q=(1)(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=12;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran H4 Syntax SAS Pengujian Model ARIMA (0,1,1)(0,1,0)¹²

```
data goldao;
input y;
datalines;
299
240
231
229
249
.
.
.
400
415
409
374
410
;
proc arima data=goldao;
identify var=y(1,12);
estimate
p=(0) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=12;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran II *Output SAS Pengujian Model ARIMA (2,1,0)*

Conditional Least Squares Estimation									
Parameter		Standard Estimate	Error	Approx t Value	Pr > t	Lag			
AR1,1		-0.68406	0.13804	-4.96	<.0001	1			
AR1,2		-0.24292	0.13805	-1.76	0.0846	2			
Variance Estimate				2389.568					
Std Error Estimate				48.8832					
AIC				554.0312					
SBC				557.9337					
Number of Residuals				52					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.70	4	0.1031	-0.034	-0.110	-0.187	-0.027	0.154	0.239
12	20.49	10	0.0250	-0.003	-0.225	-0.053	-0.091	0.319	0.161
18	26.94	16	0.0422	-0.020	-0.144	-0.071	0.232	-0.051	0.038
24	34.28	22	0.0460	-0.186	-0.041	-0.124	0.096	0.108	0.093
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.98467		Pr < W	0.7367				
Kolmogorov-Smirnov	D	0.081473		Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.055567		Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.330481		Pr > A-Sq	>0.2500				

Lampiran I2 *Output SAS Pengujian Model ARIMA (0,1,1)*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	Approx t Value	Pr > t	Lag				
MA1,1	0.63920	0.10745	5.95	<.0001	1				
Variance Estimate			2312.315						
Std Error Estimate			48.08654						
AIC			551.3521						
SBC			553.3034						
Number of Residuals			52						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.65	5	0.4597	-0.104	0.095	-0.006	0.011	0.130	0.204
12	13.92	11	0.2374	0.017	-0.136	0.062	-0.110	0.301	0.107
18	19.66	17	0.2918	0.034	-0.044	-0.075	0.212	-0.124	0.065
24	25.25	23	0.3376	-0.186	-0.013	-0.131	0.061	0.027	0.081
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.992825	Pr < W	0.9880				
Kolmogorov-Smirnov		D	0.069878	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.032896	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.20029	Pr > A-Sq	>0.2500				

Lampiran I3 *Output SAS Pengujian Model ARIMA (0,1,1)(1,0,0)¹²*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
MA1,1	0.65113	0.10900	5.97	<.0001	1				
AR1,1	0.11540	0.15281	0.76	0.4536	12				
Variance Estimate			2292.621						
Std Error Estimate			47.88132						
AIC			562.4537						
SBC			566.3943						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.44	4	0.2454	-0.135	0.126	0.004	0.009	0.154	0.182
12	15.27	10	0.1225	0.028	-0.143	0.095	-0.122	0.314	-0.009
18	22.61	16	0.1244	0.068	-0.064	-0.076	0.227	-0.151	0.066
24	27.70	22	0.1860	-0.166	0.014	-0.131	0.078	-0.004	0.075
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.992		Pr < W	0.9769				
Kolmogorov-Smirnov	D	0.077022		Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.03875		Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.217026		Pr > A-Sq	>0.2500				

Lampiran I4 *Output SAS Pengujian Model ARIMA (0,1,1)(0,1,0)*¹²

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	Approx t Value	Pr > t	Lag				
MA1,1	0.64582	0.12217	5.29	<.0001	1				
Variance Estimate			4088.614						
Std Error Estimate			63.94227						
AIC			447.1408						
SBC			448.8297						
Number of Residuals			40						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.80	5	0.0811	-0.258	0.294	0.014	0.016	0.253	0.024
12	29.48	11	0.0019	0.175	-0.139	0.204	-0.198	0.339	-0.316
18	41.30	17	0.0008	0.214	-0.068	-0.096	0.215	-0.234	0.102
24	44.74	23	0.0043	-0.120	0.037	-0.084	0.045	-0.103	0.053
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.982572	Pr < W	0.7836				
Kolmogorov-Smirnov		D	0.109858	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.050132	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.273693	Pr > A-Sq	>0.2500				

Lampiran J1 Penghitungan Manual rMSE ARIMA (0,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
399	436	37	1.369
399	497	98	9.604
399	494	95	9.025
399	392	-7	49
399	420	21	441
399	402	3	9
		<i>MSE</i>	3.416
		<i>rMSE</i>	58,448

Lampiran J2 Penghitungan Manual sMAPE ARIMA (0,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
399	436	37	835	417,5	0,088623
399	497	98	896	448	0,21875
399	494	95	893	446,5	0,212766
399	392	7	791	395,5	0,017699
399	420	21	819	409,5	0,051282
399	402	3	801	400,5	0,007491
				<i>sMAPE</i>	9,94

Lampiran J3 Penghitungan Manual rMSE ARIMA (0,1,1)(1,0,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
398	436	38	1.444
404	497	93	8.649
411	494	83	6.889
399	392	-7	49
402	420	18	324
403	402	-1	1
		<i>MSE</i>	2.893
		<i>rMSE</i>	53,784

Lampiran J4 Penghitungan Manual sMAPE ARIMA (0,1,1)(1,0,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
398	436	38	834	417	0,091127
404	497	93	901	450,5	0,206437
411	494	83	905	452,5	0,183425
399	392	7	791	395,5	0,017699
402	420	18	822	411	0,043796
403	402	1	805	402,5	0,002484
				<i>sMAPE</i>	0,090828

Lampiran K *Output Minitab Autocorrelation Function Golda A*
Lampiran K1 *Output Minitab Autocorrelation Function sebelum differencing*

Autocorrelation Function: A

Lag	ACF	T	LBQ
1	0,446106	3,28	11,35
2	0,535430	3,33	28,03
3	0,424890	2,22	38,73
4	0,476592	2,29	52,47
5	0,494224	2,18	67,54
6	0,347966	1,41	75,17
7	0,368333	1,44	83,90
8	0,303302	1,15	89,95
9	0,346163	1,28	98,00
10	0,301853	1,08	104,26
11	0,241231	0,85	108,35
12	0,249855	0,86	112,85
13	0,205624	0,70	115,97
14	0,133882	0,45	117,32
15	0,159241	0,54	119,29
16	0,077447	0,26	119,77
17	0,004667	0,02	119,77
18	0,039066	0,13	119,90
19	0,033172	0,11	119,99
20	-0,061198	-0,20	120,32
21	-0,166144	-0,56	122,85
22	-0,152631	-0,51	125,06
23	-0,152315	-0,50	127,32
24	-0,096039	-0,32	128,25
25	-0,203148	-0,67	132,55
26	-0,254110	-0,83	139,53
27	-0,258026	-0,83	146,98
28	-0,268461	-0,85	155,36
29	-0,242657	-0,76	162,49
30	-0,264577	-0,82	171,31
31	-0,277961	-0,85	181,47
32	-0,243224	-0,74	189,60
33	-0,311817	-0,93	203,60
34	-0,235972	-0,70	212,02
35	-0,239268	-0,70	221,13
36	-0,268104	-0,78	233,20

Lampiran K1 *Output Minitab Autocorrelation Function sebelum differencing (lanjutan)*

37	-0,167975	-0,48	238,22
38	-0,218269	-0,62	247,23
39	-0,150466	-0,43	251,79
40	-0,165482	-0,47	257,71
41	-0,153945	-0,43	263,22
42	-0,090454	-0,25	265,28
43	-0,197736	-0,55	276,03
44	-0,092263	-0,26	278,60
45	-0,200299	-0,56	292,08
46	-0,123693	-0,34	297,87
47	-0,129199	-0,36	305,08
48	-0,099243	-0,27	310,04
49	-0,078718	-0,22	313,79
50	-0,054682	-0,15	316,05

Lampiran K2 *Output Minitab Autocorrelation Function sesudah differencing*

```
MTB > ACF 'diff1';
SUBC>    Lags 50.
```

Autocorrelation Function: diff1

Lag	ACF	T	LBQ
1	-0,610683	-4,45	20,91
2	0,212963	1,17	23,50
3	-0,190675	-1,02	25,62
4	0,066488	0,35	25,88
5	0,100211	0,53	26,49
6	-0,086369	-0,45	26,95
7	0,032826	0,17	27,02
8	-0,070061	-0,36	27,34
9	0,075284	0,39	27,71
10	-0,020613	-0,11	27,74
11	0,003595	0,02	27,74
12	0,006992	0,04	27,75
13	0,010148	0,05	27,76
14	-0,095504	-0,49	28,44
15	0,123838	0,64	29,61
16	0,008016	0,04	29,62
17	-0,119586	-0,61	30,78

Lampiran K2 *Output Minitab Autocorrelation Function sesudah differencing (lanjutan)*

18	0,014834	0,08	30,80
19	0,090195	0,46	31,49
20	0,008796	0,04	31,50
21	-0,099494	-0,50	32,40
22	0,027178	0,14	32,47
23	-0,059999	-0,30	32,82
24	0,167465	0,84	35,64
25	-0,068658	-0,34	36,13
26	-0,033377	-0,17	36,25
27	0,008019	0,04	36,26
28	-0,024994	-0,12	36,33
29	0,022269	0,11	36,39
30	0,021562	0,11	36,45
31	-0,047088	-0,23	36,74
32	0,094888	0,47	37,99
33	-0,140383	-0,69	40,87
34	0,098195	0,48	42,34
35	0,030773	0,15	42,50
36	-0,134325	-0,65	45,59
37	0,122713	0,59	48,34
38	-0,094242	-0,45	50,06
39	0,071204	0,34	51,12
40	-0,001202	-0,01	51,12
41	-0,072750	-0,35	52,40
42	0,129753	0,61	56,86
43	-0,154752	-0,73	63,85
44	0,164389	0,77	72,60
45	-0,165603	-0,76	82,59
46	0,127733	0,58	89,39
47	-0,083899	-0,38	92,80
48	0,056793	0,26	94,69
49	-0,038134	-0,17	95,75
50	0,020528	0,09	96,15

Lampiran L1 *Output Minitab Partial Autocorrelation Function sebelum differencing*

```
MTB > PACF 'A';
SUBC>    Lags 50.
```

Partial Autocorrelation Function: A

Lag	PACF	T
1	0,446106	3,28
2	0,420004	3,09
3	0,150049	1,10
4	0,189814	1,39
5	0,222289	1,63
6	-0,082503	-0,61
7	-0,022797	-0,17
8	-0,022098	-0,16
9	0,034381	0,25
10	0,018910	0,14
11	-0,044872	-0,33
12	0,008071	0,06
13	-0,017458	-0,13
14	-0,156679	-1,15
15	0,005930	0,04
16	-0,056544	-0,42
17	-0,194763	-1,43
18	0,027738	0,20
19	0,092895	0,68
20	-0,155692	-1,14
21	-0,218766	-1,61
22	-0,042605	-0,31
23	-0,012360	-0,09
24	0,098147	0,72
25	-0,010593	-0,08
26	-0,067230	-0,49
27	-0,060122	-0,44
28	-0,116483	-0,86
29	0,023825	0,18

Lampiran L1 *Output Minitab Partial Autocorrelation Function*
sebelum *differencing* (lanjutan)

30	0,114963	0,84
31	-0,018201	-0,13
32	0,109064	0,80
33	-0,039281	-0,29
34	-0,048606	-0,36
35	0,086960	0,64
36	-0,027273	-0,20
37	0,109135	0,80
38	0,070660	0,52
39	0,006318	0,05
40	0,076523	0,56
41	-0,013811	-0,10
42	-0,066862	-0,49
43	-0,219461	-1,61
44	-0,023150	-0,17
45	-0,077893	-0,57
46	-0,022893	-0,17
47	-0,061448	-0,45
48	-0,041759	-0,31
49	-0,058775	-0,43
50	-0,008117	-0,06

Lampiran L2 *Output Minitab Partial Autocorrelation Function*
sesudah *differencing*

```
MTB > PACF 'diff1';
SUBC>    Lags 50.
```

Partial Autocorrelation Function: diff1

Lag	PACF	T
1	-0,610683	-4,45
2	-0,255110	-1,86
3	-0,312552	-2,28
4	-0,341004	-2,48
5	-0,092318	-0,67
6	-0,067439	-0,49
7	-0,063291	-0,46
8	-0,096799	-0,70

Lampiran L2 *Output Minitab Partial Autocorrelation Function*
 sesudah *differencing* (lanjutan)

9	-0,050605	-0,37
10	-0,034151	-0,25
11	-0,033132	-0,24
12	0,019565	0,14
13	0,098977	0,72
14	-0,090765	-0,66
15	-0,008369	-0,06
16	0,190526	1,39
17	-0,028964	-0,21
18	-0,185450	-1,35
19	0,055309	0,40
20	0,139105	1,01
21	-0,110109	-0,80
22	-0,093133	-0,68
23	-0,128786	-0,94
24	-0,044341	-0,32
25	0,026337	0,19
26	0,035382	0,26
27	0,078892	0,57
28	-0,020830	-0,15
29	-0,101037	-0,74
30	0,017868	0,13
31	-0,136918	-1,00
32	0,017970	0,13
33	0,069608	0,51
34	-0,048086	-0,35
35	0,048871	0,36
36	-0,078592	-0,57
37	-0,052565	-0,38
38	-0,027196	-0,20
39	-0,127322	-0,93
40	-0,037052	-0,27
41	-0,033344	-0,24
42	0,124744	0,91
43	-0,045595	-0,33
44	0,012585	0,09
45	-0,024729	-0,18
46	0,049131	0,36
47	-0,012515	-0,09
48	0,002894	0,02
49	0,006414	0,05
50	-0,068535	-0,50

Lampiran L3 *Output Minitab Autocorrelation Function sebelum differencing 12*

```
MTB > ACF 'Diff12';
SUBC>    Lags 50.
```

Autocorrelation Function: Diff12

Lag	ACF	T	LBQ
1	-0,692708	-4,44	21,15
2	0,344506	1,58	26,51
3	-0,107037	-0,46	27,05
4	-0,077350	-0,33	27,33
5	0,175822	0,75	28,84
6	-0,144562	-0,61	29,90
7	0,198878	0,83	31,95
8	-0,281029	-1,16	36,17
9	0,289979	1,16	40,80
10	-0,349187	-1,35	47,73
11	0,457517	1,70	60,04
12	-0,472565	-1,64	73,61
13	0,328852	1,07	80,42
14	-0,138877	-0,44	81,68
15	-0,113862	-0,36	82,56
16	0,284969	0,90	88,29
17	-0,316381	-0,98	95,64
18	0,229025	0,69	99,66
19	-0,163030	-0,49	101,79
20	0,126417	0,38	103,13
21	-0,135607	-0,40	104,75
22	0,119328	0,35	106,07
23	-0,117159	-0,34	107,42
24	0,126150	0,37	109,07
25	-0,073978	-0,22	109,67
26	-0,032235	-0,09	109,79
27	0,118717	0,35	111,57
28	-0,202234	-0,59	117,12
29	0,194848	0,56	122,69
30	-0,096944	-0,28	124,20
31	0,028867	0,08	124,35
32	0,008915	0,03	124,36
33	-0,053280	-0,15	124,99
34	0,050995	0,15	125,64
35	-0,044016	-0,13	126,21

Lampiran L3 *Output Minitab Autocorrelation Function sebelum differencing 12 (lanjutan)*

36	0,008613	0,02	126,24
37	0,017438	0,05	126,37
38	-0,020758	-0,06	126,62
39	0,004163	0,01	126,64
40	0,018803	0,05	127,26

Lampiran L4 *Output Minitab Partial Autocorrelation Function sesudah differencing 12*

```
MTB > PACF C3;
SUBC>    Lags 50.
```

Partial Autocorrelation Function: C3

Lag	PACF	T
1	-0,564278	-3,61
2	-0,175919	-1,13
3	-0,355819	-2,28
4	-0,473126	-3,03
5	-0,021998	-0,14
6	0,091614	0,59
7	-0,125553	-0,80
8	-0,241635	-1,55
9	0,093703	0,60
10	0,145025	0,93
11	0,237173	1,52
12	-0,058997	-0,38
13	-0,059005	-0,38
14	-0,146833	-0,94
15	-0,191377	-1,23
16	-0,077812	-0,50
17	0,065498	0,42
18	-0,195495	-1,25
19	0,039648	0,25
20	-0,079095	-0,51
21	-0,181706	-1,16
22	-0,027078	-0,17
23	0,003622	0,02
24	0,010577	0,07
25	0,024659	0,16

Lampiran L4 *Output Minitab Partial Autocorrelation Function*
sesudah *differencing* 12 (lanjutan)

26	-0,062044	-0,40
27	0,070236	0,45
28	0,000140	0,00
29	0,035444	0,23
30	-0,124946	-0,80
31	-0,009606	-0,06
32	-0,128130	-0,82
33	-0,088873	-0,57
34	-0,042729	-0,27
35	-0,110621	-0,71
36	0,002324	0,01
37	0,089071	0,57
38	-0,032164	-0,21
39	0,057217	0,37
40	-0,042591	-0,27

Lampiran M1 Syntax SAS Pengujian *Dickey Fuller* sebelum *diferencing*

```
data goldaa;  
input y;  
datalines;  
140  
136  
172  
107  
133  
.  
.  
.  
194  
266  
207  
254  
236  
;  
data goldaa;  
set goldaa;  
y1=lag1(y);  
yd=y-y1;  
run;  
proc reg data=goldaa;  
model yd=y1/noint;  
run;
```

Lampiran M2 Syntax SAS Pengujian *Dickey Fuller* sesudah *diferencing*

```
data goldaa;  
input y;  
datalines;  
*  
-4  
36  
-65  
26  
.  
.  
.  
-103  
72  
-59  
47  
-18  
;  
data goldaa;  
set goldaa;  
y1=lag1(y);  
yd=y-y1;  
run;  
proc reg data=goldaa;  
model yd=y1/noint;  
run;
```

Lampiran M3 Syntax SAS Pengujian *Dickey Fuller* sesudah *diferencing* 12

```
data goldao;
input y;
datalines;
*
*
*
*
*
.
.
.
-72
43
-140
86
-9
;
data goldao;
set goldao;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldao;
model yd=y1/noint;
run;
```

Lampiran N1 *Output SAS Hasil Pengujian Dickey Fuller Sebelum Differencing*

Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	2234.36035	2234.36035	0.75	0.3904
Error	52	154892	2978.68538		
Uncorrected Total	53	157126			
Root MSE	54.57733	R-Square	0.0142		
Dependent Mean	1.81132	Adj R-Sq	-0.0047		
Coeff Var	3013.12364				
Parameter Estimates					
Parameter Variable	DF	Standard Estimate	Error	t Value	Pr > t
y1	1	-0.03692	0.04263	-0.87	0.3904

Lampiran N2 *Output SAS Hasil Pengujian Dickey Fuller Sesudah Differencing 1*

Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	406388	406388	209.80	<.0001
Error	51	98786	1936.98435		
Uncorrected Total	52	505174			
Root MSE	44.01118	R-Square	0.8045		
Dependent Mean	-0.26923	Adj R-Sq	0.8006		
Coeff Var	-16347				
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1	1	-1.60988	0.11114	-14.48	<.0001

Lampiran N3 *Output SAS Hasil Pengujian Dickey Fuller Sesudah Differencing 12*

Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	476504	476504	138.41	<.0001
Error	38	130825	3442.76613		
Uncorrected Total	39	607329			
Root MSE		58.67509	R-Square	0.7846	
Dependent Mean		3.46154	Adj R-Sq	0.7789	
Coeff Var		1695.05814			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1	1	-1.58219	0.13449	-11.76	<.0001

Lampiran O1 Syntax SAS Pengujian Model ARIMA ([1,3,4],1,0)

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldaa;
identify var=y(1);
estimate
p=(1,3,4) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```


Lampiran O2 Syntax SAS Pengujian Model ARIMA (0,1,1)(0,1,0)¹²

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldaa;
identify var=y(1,12);
estimate
p=(0) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran O3 Syntax SAS Pengujian Model ARIMA (1,1,0)(0,1,0)¹²

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldaa;
identify var=y(1,12);
estimate
p=(1) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran O4 Syntax SAS Pengujian Model ARIMA (3,1,0)(0,1,0)¹²

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldaa;
identify var=y(1,12);
estimate
p=(3) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran O5 Syntax SAS Pengujian Model ARIMA (4,1,0)(0,1,0)¹²

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldaa;
identify var=y(1,12);
estimate
p=(4) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran O6 Syntax SAS Pengujian Model ARIMA
([1,3,4],1,0)(0,1,0)¹²

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldaa;
identify var=y(1,12);
estimate
p=(1,3,4) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran P1 *Output SAS Pengujian Model ARIMA ([1,3,4],1,0)*

Conditional Least Squares Estimation									
Parameter		Standard Estimate	Error	t Value	Pr > t	Lag			
AR1,1		-0.60404	0.11387	-5.30	<.0001	1			
AR1,2		-0.14218	0.14125	-1.01	0.3190	3			
AR1,3		-0.13043	0.14304	-0.91	0.3662	4			
Variance Estimate				1930.506					
Std Error Estimate				43.93752					
AIC				554.2927					
SBC				560.2036					
Number of Residuals				53					
* AIC and SBC do not include log determinant. Autocorrelation Check of Residuals									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.55	3	0.0229	-0.188	-0.325	-0.011	0.075	0.131	-0.048
12	10.71	9	0.2963	-0.077	-0.009	0.082	0.007	-0.002	0.068
18	21.91	15	0.1103	-0.062	-0.110	0.222	0.058	-0.271	0.009
24	34.04	21	0.0359	0.236	-0.005	-0.148	-0.060	0.050	0.218
Tests for Normality									
Test		--Statistic--		----p Value-----					
Shapiro-Wilk		W	0.952854	Pr < W	0.0357				
Kolmogorov-Smirnov		D	0.109578	Pr > D	0.1109				
Cramer-von Mises		W-Sq	0.143552	Pr > W-Sq	0.0285				
Anderson-Darling		A-Sq	0.862749	Pr > A-Sq	0.0248				

Lampiran P2 *Output SAS Pengujian Model ARIMA (0,1,1)(0,1,0)*¹²

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
MA1,1	0.84448	0.08551	9.88	<.0001	1				
Variance Estimate			2694.972						
Std Error Estimate			51.91312						
AIC			441.2054						
SBC			442.919						
Number of Residuals			41						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.66	5	0.1758	-0.072	0.080	-0.201	0.099	0.313	0.007
12	21.41	11	0.0294	-0.090	-0.064	0.222	0.082	-0.064	-0.401
18	27.87	17	0.0465	-0.049	0.007	0.140	-0.074	-0.219	-0.118
24	35.56	23	0.0457	0.101	-0.102	-0.058	-0.111	0.015	0.209
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.968842	Pr < W	0.3159					
Kolmogorov-Smirnov	D	0.093352	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.055906	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.395911	Pr > A-Sq	>0.2500					

Lampiran P3 *Output SAS Pengujian Model ARIMA (1,1,0)(0,1,0)¹²*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Approx Pr > t	Lag				
AR1,1	-0.56433	0.13057	-4.32	<.0001	1				
Variance Estimate			3371.241						
Std Error Estimate			58.06239						
AIC			450.385						
SBC			452.0986						
Number of Residuals			41						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	18.54	5	0.0023	-0.097	-0.304	-0.324	0.060	0.425	-0.032
12	44.09	11	<.0001	-0.294	-0.115	0.287	0.246	-0.095	-0.441
18	57.41	17	<.0001	-0.032	0.178	0.257	-0.027	-0.298	-0.042
24	73.26	23	<.0001	0.239	-0.024	-0.080	-0.153	0.044	0.283
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.983074	Pr < W	0.7901					
Kolmogorov-Smirnov	D	0.103007	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.065354	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.344399	Pr > A-Sq	>0.2500					

Lampiran P4 *Output SAS Pengujian Model ARIMA (3,1,0)(0,1,0)*¹²

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
AR1,1	-0.30967	0.16299	-1.90	0.0647	3				
Variance Estimate			4536.269						
Std Error Estimate			67.35183						
AIC			462.5548						
SBC			464.2684						
Number of Residuals			41						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	22.03	5	0.0005	-0.586	0.143	-0.045	-0.144	0.302	-0.095
12	28.77	11	0.0025	-0.104	0.010	0.057	0.026	0.094	-0.299
18	34.32	17	0.0076	0.168	-0.069	0.084	0.070	-0.189	-0.018
24	50.15	23	0.0009	0.209	-0.193	0.124	-0.090	-0.070	0.253
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.978259	Pr < W	0.6100					
Kolmogorov-Smirnov	D	0.085263	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.036072	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.250955	Pr > A-Sq	>0.2500					

Lampiran P5 *Output SAS Pengujian Model ARIMA (4,1,0)(0,1,0)¹²*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
AR1,1	0.04727	0.17096	0.28	0.7836	4				
Variance Estimate			4936.19						
Std Error Estimate			70.25802						
AIC			466.0189						
SBC			467.7324						
Number of Residuals			41						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	22.37	5	0.0004	-0.565	0.196	-0.243	0.006	0.258	-0.105
12	31.56	11	0.0009	-0.056	-0.101	0.178	0.015	0.082	-0.322
18	35.72	17	0.0050	0.139	-0.035	0.151	-0.016	-0.124	-0.050
24	45.99	23	0.0030	0.194	-0.127	0.055	-0.085	-0.035	0.216
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.977995		Pr < W	0.6002				
Kolmogorov-Smirnov	D	0.088077		Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.041836		Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.277809		Pr > A-Sq	>0.2500				

Lampiran P6 *Output* SAS Pengujian Model ARIMA
([1,3,4],1,0)(0,1,0)¹²

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	Approx t Value	Pr > t	Lag				
AR1,1	-0.58321	0.13016	-4.48	<.0001	1				
AR1,2	-0.36015	0.16017	-2.25	0.0304	3				
AR1,3	-0.33177	0.16450	-2.02	0.0508	4				
Variance Estimate			3061.813						
Std Error Estimate			55.33365						
AIC			448.3348						
SBC			453.4755						
Number of Residuals			41						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	12.22	3	0.0067	-0.158	-0.307	-0.079	0.007	0.366	0.013
12	29.14	9	0.0006	-0.326	-0.042	0.188	0.156	-0.048	-0.359
18	40.56	15	0.0004	0.012	0.072	0.176	0.024	-0.348	-0.016
24	56.61	21	<.0001	0.255	-0.083	-0.020	-0.130	0.008	0.288
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.9738	Pr < W	0.4547				
Kolmogorov-Smirnov		D	0.088436	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.04733	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.318505	Pr > A-Sq	>0.2500				

Lampiran Q1 Penghitungan Manual rMSE ARIMA ([1,3,4],1,0)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
246	234	-12	144
241	303	62	3.844
241	263	22	484
242	238	-4	16
241	188	-53	2.809
242	241	-1	1
		<i>MSE</i>	1.216
		<i>rMSE</i>	34,876

Lampiran Q2 Penghitungan Manual sMAPE ARIMA ([1,3,4],1,0)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
246	234	12	480	240	0,05
241	303	62	544	272	0,227941
241	263	22	504	252	0,087302
242	238	4	480	240	0,016667
241	188	53	429	214,5	0,247086
242	241	1	483	241,5	0,004141
				<i>sMAPE</i>	0,105523

Lampiran Q3 Penghitungan Manual rMSE ARIMA (0,1,1)(0,1,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
158	234	76	5.776
301	303	2	4
246	263	17	289
220	238	18	324
247	188	-59	3.481
189	241	52	2.704
		<i>MSE</i>	2,096
		<i>rMSE</i>	45,786

Lampiran Q4 Penghitungan Manual sMAPE ARIMA (0,1,1)(0,1,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
158	234	76	392	196	0,387755
301	303	2	604	302	0,006623
246	263	17	509	254,5	0,066798
220	238	18	458	229	0,078603
247	188	59	435	217,5	0,271264
189	241	52	430	215	0,24186
				<i>sMAPE</i>	0,175484

Lampiran Q5 Penghitungan Manual rMSE ARIMA (1,1,0)(0,1,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
141	234	93	8.649
267	303	36	1.296
221	263	42	1.764
190	238	48	2.304
220	188	-32	1.024
151	241	90	8.100
		<i>MSE</i>	3,856
		<i>rMSE</i>	62,098

Lampiran Q6 Penghitungan Manual sMAPE ARIMA (1,1,0)(0,1,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
141	234	93	375	187,5	0,496
267	303	36	570	285	0,126316
221	263	42	484	242	0,173554
190	238	48	428	214	0,224299
220	188	32	408	204	0,156863
151	241	90	392	196	0,459184
				<i>sMAPE</i>	0,2727

Lampiran Q7 Penghitungan Manual rMSE ARIMA
 ([1,3,4],1,0)(0,1,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
180	234	54	2.916
300	303	3	9
247	263	16	256
211	238	27	729
233	188	-45	2.025
176	241	65	4.225
		<i>MSE</i>	1,693
		<i>rMSE</i>	41,150

Lampiran Q8 Penghitungan Manual sMAPE ARIMA
 ([1,3,4],1,0)(0,1,0)¹²

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
180	234	54	414	207	0,26087
300	303	3	603	301,5	0,00995
247	263	16	510	255	0,062745
211	238	27	449	224,5	0,120267
233	188	45	421	210,5	0,213777
176	241	65	417	208,5	0,311751
				<i>sMAPE</i>	0,163

Lampiran R *Output Minitab Autocorrelation Function Golda B*
Lampiran R1 *Output Minitab Autocorrelation Function sebelum differencing*

```
MTB > ACF 'B';
SUBC>    Lags 50.
```

Autocorrelation Function: B

Lag	ACF	T	LBQ
1	0,734887	5,40	30,81
2	0,748846	3,82	63,42
3	0,707268	2,90	93,09
4	0,669468	2,40	120,19
5	0,629138	2,05	144,62
6	0,601513	1,82	167,41
7	0,526504	1,50	185,25
8	0,453179	1,24	198,75
9	0,428820	1,14	211,11
10	0,357822	0,93	219,91
11	0,373973	0,96	229,74
12	0,352360	0,89	238,68
13	0,235480	0,59	242,77
14	0,201739	0,50	245,85
15	0,124159	0,31	247,04
16	0,086413	0,21	247,64
17	0,010243	0,03	247,65
18	-0,038786	-0,10	247,77
19	-0,049288	-0,12	247,98
20	-0,156244	-0,38	250,15
21	-0,186535	-0,46	253,34
22	-0,243218	-0,59	258,93
23	-0,211166	-0,51	263,28
24	-0,309558	-0,75	272,94
25	-0,256332	-0,61	279,79
26	-0,343227	-0,81	292,52
27	-0,355653	-0,83	306,68
28	-0,367787	-0,85	322,42
29	-0,406043	-0,93	342,36
30	-0,390386	-0,88	361,56
31	-0,375353	-0,83	380,08
32	-0,380702	-0,83	400,01
33	-0,403413	-0,87	423,44
34	-0,354955	-0,76	442,49
35	-0,321704	-0,68	458,96
36	-0,303970	-0,63	474,49

Lampiran R1 *Output Minitab Autocorrelation Function sebelum differencing (lanjutan)*

37	-0,241449	-0,50	484,86
38	-0,258096	-0,53	497,45
39	-0,238194	-0,49	508,88
40	-0,217246	-0,44	519,08
41	-0,202798	-0,41	528,65
42	-0,178816	-0,36	536,70
43	-0,177451	-0,36	545,36
44	-0,158257	-0,32	552,93
45	-0,166465	-0,34	562,24
46	-0,123254	-0,25	567,99
47	-0,101423	-0,20	572,43
48	-0,080938	-0,16	575,73
49	-0,052312	-0,11	577,39
50	-0,040740	-0,08	578,64

Lampiran R2 *Output Minitab Autocorrelation Function sesudah differencing*

```
MTB > ACF C2;
SUBC>    Lags 50.
```

Autocorrelation Function: C2

Lag	ACF	T	LBQ
1	-0,562827	-4,10	17,76
2	0,122079	0,70	18,61
3	-0,015444	-0,09	18,62
4	0,001068	0,01	18,62
5	-0,047038	-0,27	18,76
6	0,107950	0,61	19,48
7	-0,019980	-0,11	19,51
8	-0,080131	-0,45	19,92
9	0,110717	0,62	20,73
10	-0,182620	-1,01	22,99
11	0,102490	0,56	23,72
12	0,154895	0,84	25,43
13	-0,179648	-0,96	27,78
14	0,095347	0,50	28,46
15	-0,066205	-0,35	28,80
16	0,067488	0,35	29,16
17	-0,061439	-0,32	29,46

Lampiran R2 *Output Minitab Autocorrelation Function sesudah differencing (lanjutan)*

18	-0,064775	-0,34	29,81
19	0,170922	0,88	32,32
20	-0,128002	-0,65	33,76
21	0,062390	0,32	34,12
22	-0,191407	-0,97	37,56
23	0,287825	1,43	45,61
24	-0,324320	-1,55	56,19
25	0,286521	1,31	64,73
26	-0,146027	-0,65	67,03
27	0,020931	0,09	67,08
28	0,021211	0,09	67,14
29	-0,065424	-0,29	67,66
30	0,006061	0,03	67,66
31	0,023471	0,10	67,73
32	0,031482	0,14	67,87
33	-0,135110	-0,59	70,53
34	0,073264	0,32	71,35
35	0,014287	0,06	71,39
36	-0,076757	-0,33	72,40
37	0,133315	0,58	75,64
38	-0,063380	-0,27	76,42
39	-0,012077	-0,05	76,45
40	0,033745	0,15	76,70
41	-0,031670	-0,14	76,95
42	0,023731	0,10	77,10
43	-0,019454	-0,08	77,21
44	0,039105	0,17	77,70
45	-0,086201	-0,37	80,41
46	0,081402	0,35	83,17
47	-0,048824	-0,21	84,33
48	0,019921	0,09	84,56
49	0,013963	0,06	84,70
50	-0,000251	-0,00	84,70

Lampiran S1 *Output Minitab Partial Autocorrelation Function
sebelum differencing*

```
MTB > PACF 'B';
SUBC>     Lags 50.
```

Partial Autocorrelation Function: B

Lag	PACF	T
1	0,734887	5,40
2	0,453943	3,34
3	0,200366	1,47
4	0,065644	0,48
5	0,000877	0,01
6	0,012422	0,09
7	-0,115166	-0,85
8	-0,175533	-1,29
9	-0,019968	-0,15
10	-0,057735	-0,42
11	0,148437	1,09
12	0,148244	1,09
13	-0,213251	-1,57
14	-0,153094	-1,13
15	-0,189001	-1,39
16	-0,079086	-0,58
17	-0,130352	-0,96
18	-0,086087	-0,63
19	0,232394	1,71
20	-0,035585	-0,26
21	-0,051303	-0,38
22	-0,110396	-0,81
23	0,051152	0,38
24	-0,173736	-1,28
25	0,141862	1,04
26	-0,037339	-0,27
27	-0,001884	-0,01
28	-0,002548	-0,02
29	-0,042272	-0,31

Lampiran S1 *Output Minitab Partial Autocorrelation Function*
sebelum *differencing* (lanjutan)

30	-0,024002	-0,18
31	0,034280	0,25
32	0,131998	0,97
33	0,014814	0,11
34	0,043048	0,32
35	0,089567	0,66
36	0,043110	0,32
37	-0,034797	-0,26
38	-0,109377	-0,80
39	-0,116462	-0,86
40	-0,002173	-0,02
41	-0,006205	-0,05
42	-0,046917	-0,34
43	-0,035999	-0,26
44	-0,086446	-0,64
45	0,024594	0,18
46	-0,071764	-0,53
47	0,038501	0,28
48	-0,086570	-0,64
49	0,082342	0,61
50	-0,045868	-0,34

Lampiran S2 *Output Minitab Partial Autocorrelation Function*
sesudah *differencing*

MTB > PACF C2;
SUBC> Lags 50.

Partial Autocorrelation Function: C2

Lag	PACF	T
1	-0,562827	-4,10
2	-0,284963	-2,07
3	-0,139450	-1,02
4	-0,068396	-0,50
5	-0,110469	-0,80
6	0,040732	0,30
7	0,123014	0,90
8	-0,013867	-0,10

Lampiran S2 *Output Minitab Partial Autocorrelation Function*
 sesudah *differencing* (lanjutan)

9	0,064183	0,47
10	-0,152666	-1,11
11	-0,138724	-1,01
12	0,207327	1,51
13	0,089813	0,65
14	0,094320	0,69
15	-0,006100	-0,04
16	0,078521	0,57
17	0,038906	0,28
18	-0,283546	-2,06
19	-0,001861	-0,01
20	0,012783	0,09
21	0,050915	0,37
22	-0,199502	-1,45
23	0,042679	0,31
24	-0,222251	-1,62
25	-0,013696	-0,10
26	-0,019198	-0,14
27	-0,025742	-0,19
28	-0,012897	-0,09
29	0,008328	0,06
30	-0,023883	-0,17
31	-0,156387	-1,14
32	-0,082709	-0,60
33	-0,082677	-0,60
34	-0,095183	-0,69
35	-0,067341	-0,49
36	0,016870	0,12
37	0,079910	0,58
38	0,102786	0,75
39	-0,042659	-0,31
40	0,016260	0,12
41	0,044240	0,32
42	-0,010083	-0,07
43	0,053333	0,39
44	-0,050075	-0,36
45	0,050419	0,37
46	-0,061012	-0,44
47	0,047913	0,35
48	-0,134642	-0,98
49	-0,018035	-0,13
50	-0,010459	-0,08

Lampiran S3 *Output Minitab Autocorrelation Function sesudah differencing 12*

```
MTB > ACF C3;
SUBC>    Lags 50.
```

Autocorrelation Function: C3

Lag	ACF	T	LBQ
1	-0,611117	-3,91	16,46
2	0,179364	0,87	17,91
3	-0,064867	-0,31	18,11
4	0,067643	0,32	18,33
5	-0,044125	-0,21	18,42
6	0,100440	0,48	18,93
7	-0,059608	-0,28	19,12
8	-0,092783	-0,44	19,58
9	0,164530	0,77	21,07
10	-0,165320	-0,76	22,62
11	0,229778	1,04	25,72
12	-0,144354	-0,64	26,99
13	-0,078280	-0,34	27,38
14	0,096058	0,42	27,98
15	0,063970	0,28	28,26
16	-0,133395	-0,58	29,51
17	0,111213	0,48	30,42
18	-0,144241	-0,62	32,01
19	0,132787	0,56	33,43
20	-0,059694	-0,25	33,73
21	0,032255	0,14	33,82
22	-0,048622	-0,20	34,04
23	0,060366	0,25	34,40
24	-0,109409	-0,46	35,64
25	0,076258	0,32	36,28
26	-0,013165	-0,05	36,30
27	-0,067143	-0,28	36,87
28	0,079779	0,33	37,73
29	-0,054989	-0,23	38,17
30	-0,006413	-0,03	38,18
31	0,030491	0,13	38,34
32	-0,047154	-0,20	38,78
33	0,031977	0,13	39,00
34	0,005805	0,02	39,01
35	-0,025538	-0,11	39,20

Lampiran S3 *Output Minitab Autocorrelation Function* sesudah differencing 12 (lanjutan)

36	0,030514	0,13	39,53
37	-0,026445	-0,11	39,84
38	0,006924	0,03	39,87
39	-0,002717	-0,01	39,88
40	-0,000775	-0,00	39,88

Lampiran S4 *Output Minitab Partial Autocorrelation Function* sesudah differencing 12

```
MTB > PACF C3;
SUBC>     Lags 50.
```

Partial Autocorrelation Function: C3

Lag	PACF	T
1	-0,611117	-3,91
2	-0,309799	-1,98
3	-0,195304	-1,25
4	-0,043962	-0,28
5	-0,003531	-0,02
6	0,158311	1,01
7	0,178300	1,14
8	-0,081863	-0,52
9	0,021381	0,14
10	-0,119593	-0,77
11	0,143588	0,92
12	0,183869	1,18
13	-0,121614	-0,78
14	-0,114042	-0,73
15	0,050701	0,32
16	-0,047728	-0,31
17	0,023277	0,15
18	-0,146413	-0,94
19	0,056525	0,36
20	0,009451	0,06
21	-0,033868	-0,22
22	-0,023778	-0,15
23	0,051350	0,33
24	-0,016252	-0,10
25	-0,096069	-0,62

Lampiran S4 *Output Minitab Partial Autocorrelation Function*
sesudah *differencing* 12 (lanjutan)

26	-0,181253	-1,16
27	-0,093133	-0,60
28	0,015180	0,10
29	0,036347	0,23
30	-0,086659	-0,55
31	-0,031769	-0,20
32	-0,050034	-0,32
33	0,006586	0,04
34	-0,017230	-0,11
35	0,059426	0,38
36	0,132147	0,85
37	0,030027	0,19
38	-0,067936	-0,44
39	-0,062675	-0,40
40	-0,069185	-0,44

Lampiran T1 Syntax SAS Pengujian *Dickey Fuller* sebelum *diferencing*

```
data goldab;
input y;
datalines;
216
183
185
203
187
.
.
.
307
305
284
321
274
;
data goldab;
set goldab;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldab;
model yd=y1/noint;
run;
```

Lampiran T2 Syntax SAS Pengujian *Dickey Fuller* sesudah *differencing*

```
data goldab;
input y;
datalines;
*
-33
2
18
-16
.
.
.
-39
-2
-21
37
-47
;
data goldab;
set goldab;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldab;
model yd=y1/noint;
run;
```

Lampiran T3 Syntax SAS Pengujian *Dickey Fuller* sesudah *diferencing* 12

```
data goldab;
input y;
datalines;
*
*
*
*
*
.
.
.
-33
15
-57
19
-12
;
data goldab;
set goldab;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldab;
model yd=y1/noint;
run;
```

Lampiran U1 *Output SAS Hasil Pengujian Dickey Fuller Sebelum Differencing*

Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	1	547.97143	547.97143	0.26	0.6097	
Error		52	107988	2076.69286		
	Uncorrected Total	53	108536			
	Root MSE	45.57075	R-Square	0.0050		
	Dependent Mean	1.09434	Adj R-Sq	-0.0141		
	Coeff Var		4164.22331			
Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
y1	1	-0.01368	0.02663	-0.51	0.6097	

Lampiran U2 *Output SAS Hasil Pengujian Dickey Fuller Sesudah Differencing*

Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	1	263005	263005	184.84	<.0001	
Error	51	72567	1422.88190			
	Uncorrected Total	52	335572			
	Root MSE	37.72111	R-Square	0.7838		
	Dependent Mean	-0.26923	Adj R-Sq	0.7795		
	Coeff Var	-14011				
Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
y1	1	-1.57275	0.11568	-13.60	<.0001	

Lampiran V1 Syntax SAS Pengujian Model ARIMA (0,1,1)

```
data goldab;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldab;
identify var=y(1);
estimate
p=(0) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran V2 Syntax SAS Pengujian Model ARIMA (1,1,0)

```
data goldaa;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldab;
identify var=y(1);
estimate
p=(1) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran V3 Syntax SAS Pengujian Model ARIMA (1,1,1)

```
data goldab;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldab;
identify var=y(1);
estimate
p=(1) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran V4 Syntax SAS Pengujian Model ARIMA (2,1,0)

```
data goldab;
input y;
datalines;
140
136
172
107
133
.
.
.
194
266
207
254
236;
proc arima data=goldab;
identify var=y(1);
estimate
p=(2) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```


Lampiran V5 Syntax SAS Pengujian Model ARIMA (2,1,1)

```
data goldab;
input y;
datalines;
140
136
172
107\
133
.
.
.
194
266
207
254
236;
proc arima data=goldab;
identify var=y(1);
estimate
p=(2) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran W1 *Output SAS Pengujian Model ARIMA (0,1,1)*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Approx Pr > t	Lag				
MA1,1	0.65171	0.10573	6.16	<.0001	1				
Variance Estimate			1316.548						
Std Error Estimate			36.28427						
AIC			532.0847						
SBC			534.055						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.37	5	0.6432	-0.129	0.107	0.044	0.036	0.029	0.158
12	10.03	11	0.5275	0.039	-0.028	0.083	-0.084	0.188	0.210
18	11.53	17	0.8276	-0.080	0.066	-0.020	0.029	-0.075	-0.044
24	24.00	23	0.4036	0.121	-0.101	-0.046	-0.166	0.169	-0.217
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.982706	Pr < W	0.6345					
Kolmogorov-Smirnov	D	0.093353	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.069853	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.418496	Pr > A-Sq	>0.2500					

Lampiran W2 *Output SAS Pengujian Model ARIMA (1,1,0)*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
AR1,1	-0.57275	0.11542	-4.96	<.0001	1				
Variance Estimate			1416.461						
Std Error Estimate			37.6359						
AIC			535.9615						
SBC			537.9318						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.81	5	0.2348	-0.160	-0.236	0.070	-0.054	-0.004	0.168
12	14.84	11	0.1899	-0.007	-0.060	0.010	-0.169	0.192	0.214
18	17.44	17	0.4249	-0.143	-0.002	0.022	0.022	-0.110	-0.025
24	27.76	23	0.2251	0.175	-0.035	-0.144	-0.072	0.151	-0.173
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.989695	Pr < W	0.9267					
Kolmogorov-Smirnov	D	0.076652	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.024817	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.180122	Pr > A-Sq	>0.2500					

Lampiran W3 *Output SAS Pengujian Model ARIMA (1,1,1)*

Conditional Least Squares Estimation									
Parameter		Standard Estimate	Error	t Value	Pr > t	Lag			
MA1,1		0.51987	0.17501	2.97	0.0045	1			
AR1,1		-0.26108	0.19828	-1.32	0.1938	1			
Variance Estimate				1295.993					
Std Error Estimate				35.99991					
AIC				532.2215					
SBC				536.1621					
Number of Residuals				53					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.70	4	0.7905	-0.004	-0.012	0.008	-0.006	0.029	0.162
12	9.19	10	0.5145	0.035	-0.043	0.027	-0.004	0.210	0.229
18	10.28	16	0.8518	-0.064	0.031	-0.008	0.007	-0.089	-0.028
24	19.07	22	0.6411	0.127	-0.075	-0.103	-0.140	0.130	-0.157
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.991659	Pr < W	0.9715				
Kolmogorov-Smirnov		D	0.066765	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.025328	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.177704	Pr > A-Sq	>0.2500				

Lampiran W4 *Output SAS Pengujian Model ARIMA (2,1,0)*

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
AR1,1	0.12722	0.13991	0.91	0.3674	2				
Variance Estimate			2054.562						
Std Error Estimate			45.32727						
AIC			555.6723						
SBC			557.6426						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	15.73	5	0.0076	-0.507	0.002	0.061	-0.027	-0.044	0.125
12	22.47	11	0.0209	-0.028	-0.071	0.105	-0.200	0.119	0.166
18	26.56	17	0.0648	-0.187	0.074	-0.036	0.064	-0.075	-0.057
24	47.40	23	0.0020	0.176	-0.096	0.004	-0.141	0.259	-0.299
Tests for Normality									
Test			--Statistic--	-----p Value-----					
Shapiro-Wilk			W	0.98162	Pr < W	0.5845			
Kolmogorov-Smirnov			D	0.077116	Pr > D	>0.1500			
Cramer-von Mises			W-Sq	0.052143	Pr > W-Sq	>0.2500			
Anderson-Darling			A-Sq	0.368072	Pr > A-Sq	>0.2500			

Lampiran W5 *Output SAS Pengujian Model ARIMA (2,1,1)*

Conditional Least Squares Estimation									
Parameter		Standard Estimate		Error	Approx t Value		Pr > t		Lag
MA1,1		0.69028		0.11608	5.95		<.0001		1
AR1,1		0.13886		0.15995	0.87		0.3894		2
Variance Estimate					1322.821				
Std Error Estimate					36.37061				
AIC					533.3074				
SBC					537.248				
Number of Residuals					53				
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.67	4	0.6136	-0.083	-0.006	0.075	0.019	0.035	0.174
12	9.90	10	0.4492	0.036	-0.025	0.062	-0.097	0.201	0.219
18	11.37	16	0.7863	-0.088	0.041	0.003	0.024	-0.087	-0.036
24	21.49	22	0.4906	0.132	-0.075	-0.093	-0.129	0.146	-0.192
Tests for Normality									
Test				--Statistic--		-----p Value-----			
Shapiro-Wilk				W	0.991717	Pr < W		0.9725	
Kolmogorov-Smirnov				D	0.079393	Pr > D		>0.1500	
Cramer-von Mises				W-Sq	0.03239	Pr > W-Sq		>0.2500	
Anderson-Darling				A-Sq	0.20708	Pr > A-Sq		>0.2500	

Lampiran X1 Penghitungan Manual rMSE ARIMA (1,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
302	344	42	1.764
295	314	19	361
297	285	-12	144
296	340	44	1.936
296	341	45	2.025
296	293	-3	9
		<i>MSE</i>	1.040
		<i>rMSE</i>	32,246

Lampiran X2 Penghitungan Manual sMAPE ARIMA (1,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
302	344	42	646	323	0,130031
295	314	19	609	304,5	0,062397
297	285	12	582	291	0,041237
296	340	44	636	318	0,138365
296	341	45	637	318,5	0,141287
296	293	3	589	294,5	0,010187
				<i>sMAPE</i>	0,087251

Lampiran X3 Penghitungan Manual rMSE ARIMA (2,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
301	344	43	1.849
294	314	20	400
298	285	-13	169
297	340	43	1.849
298	341	43	1.849
298	293	-5	25
		<i>MSE</i>	1.024
		<i>rMSE</i>	31,992

Lampiran X4 Penghitungan Manual sMAPE ARIMA (2,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
301	344	43	645	322,5	0,133333
294	314	20	608	304	0,065789
298	285	13	583	291,5	0,044597
297	340	43	637	318,5	0,135008
298	341	43	639	319,5	0,134585
298	293	5	591	295,5	0,01692
				<i>sMAPE</i>	0,088372

Lampiran Y *Output Minitab Autocorrelation Function Golda AB*
Lampiran Y1 *Output Minitab Autocorrelation Function sebelum differencing*

```
MTB > ACF 'AB';
SUBC>    Lags 50.
```

Autocorrelation Function: AB

Lag	ACF	T	LBQ
1	0,284378	2,09	4,61
2	0,241323	1,65	8,00
3	0,358689	2,33	15,63
4	0,351513	2,08	23,10
5	0,342382	1,88	30,34
6	0,355766	1,84	38,31
7	0,139854	0,68	39,57
8	0,304730	1,47	45,67
9	0,238404	1,11	49,49
10	0,171551	0,78	51,52
11	0,168475	0,76	53,51
12	0,235214	1,05	57,50
13	0,109191	0,48	58,37
14	0,162800	0,71	60,38
15	0,126545	0,54	61,62
16	-0,002306	-0,01	61,62
17	-0,050756	-0,22	61,83
18	0,048121	0,21	62,03
19	0,042670	0,18	62,18
20	-0,041590	-0,18	62,34
21	-0,165075	-0,70	64,83
22	-0,093087	-0,39	65,65
23	-0,055035	-0,23	65,95
24	-0,074830	-0,32	66,51
25	-0,201440	-0,85	70,74
26	-0,172770	-0,72	73,97
27	-0,171131	-0,70	77,25
28	-0,169565	-0,69	80,59
29	-0,255123	-1,03	88,46
30	-0,138268	-0,55	90,87
31	-0,225012	-0,89	97,53
32	-0,197451	-0,77	102,89
33	-0,171796	-0,66	107,14
34	-0,233067	-0,89	115,35
35	-0,239668	-0,90	124,49
36	-0,107142	-0,40	126,42

Lampiran Y1 *Output Minitab Autocorrelation Function sebelum differencing (lanjutan)*

37	-0,142891	-0,53	130,06
38	-0,183109	-0,67	136,39
39	-0,104629	-0,38	138,60
40	-0,114513	-0,42	141,43
41	-0,141622	-0,51	146,10
42	-0,029862	-0,11	146,32
43	-0,117201	-0,42	150,10
44	-0,132443	-0,48	155,40
45	-0,003329	-0,01	155,41
46	-0,154962	-0,55	164,48
47	-0,069493	-0,25	166,57
48	-0,058914	-0,21	168,32
49	-0,052014	-0,18	169,96
50	-0,040528	-0,14	171,20

Lampiran Y2 *Output Minitab Autocorrelation Function sesudah differencing*

MTB > ACF C2;
SUBC> Lags 50.

Autocorrelation Function: C2

Lag	ACF	T	LBQ
1	-0,452767	-3,30	11,49
2	-0,156225	-0,96	12,89
3	0,115155	0,69	13,66
4	0,017631	0,11	13,68
5	-0,082109	-0,49	14,09
6	0,213176	1,27	16,91
7	-0,263407	-1,52	21,30
8	0,147756	0,82	22,72
9	-0,005923	-0,03	22,72
10	-0,032108	-0,18	22,79
11	-0,035547	-0,19	22,88
12	0,129491	0,71	24,07
13	-0,177575	-0,96	26,37
14	0,101301	0,54	27,13
15	0,073695	0,39	27,55
16	-0,041635	-0,22	27,69
17	-0,136047	-0,72	29,19

Lampiran Y2 *Output Minitab Autocorrelation Function sesudah differencing (lanjutan)*

18	0,064773	0,34	29,54
19	0,042345	0,22	29,69
20	0,064011	0,33	30,05
21	-0,166411	-0,86	32,57
22	0,061702	0,32	32,93
23	0,025899	0,13	33,00
24	0,068889	0,35	33,47
25	-0,106055	-0,54	34,65
26	0,051053	0,26	34,93
27	-0,040207	-0,20	35,11
28	0,074136	0,38	35,75
29	-0,129264	-0,65	37,78
30	0,166234	0,83	41,28
31	-0,097383	-0,48	42,54
32	-0,028034	-0,14	42,65
33	0,055310	0,27	43,09
34	0,027376	0,13	43,21
35	-0,118365	-0,58	45,48
36	0,115204	0,56	47,75
37	0,010353	0,05	47,77
38	-0,104236	-0,51	49,88
39	0,072444	0,35	50,98
40	0,041209	0,20	51,36
41	-0,141537	-0,68	56,22
42	0,133778	0,64	60,96
43	-0,044536	-0,21	61,54
44	-0,099602	-0,47	64,76
45	0,181839	0,86	76,80
46	-0,115081	-0,53	82,32
47	0,005294	0,02	82,33
48	0,039910	0,18	83,26
49	-0,026763	-0,12	83,78
50	-0,009241	-0,04	83,87

Lampiran Z1 *Output Minitab Partial Autocorrelation Function sebelum differencing*

```
MTB > PACF 'AB';
SUBC>    Lags 50.
```

Partial Autocorrelation Function: AB

Lag	PACF	T
1	0,284378	2,09
2	0,174570	1,28
3	0,283237	2,08
4	0,217686	1,60
5	0,189642	1,39
6	0,175182	1,29
7	-0,142930	-1,05
8	0,096412	0,71
9	-0,051578	-0,38
10	-0,044901	-0,33
11	-0,044721	-0,33
12	0,078425	0,58
13	-0,049749	-0,37
14	0,005995	0,04
15	0,011937	0,09
16	-0,176682	-1,30
17	-0,215239	-1,58
18	-0,059354	-0,44
19	0,062330	0,46
20	-0,056338	-0,41
21	-0,128814	-0,95
22	0,005002	0,04
23	0,002226	0,02
24	0,000546	0,00
25	-0,084617	-0,62
26	-0,031682	-0,23
27	-0,080863	-0,59
28	-0,030312	-0,22
29	-0,060831	-0,45

Lampiran Z1 *Output Minitab Partial Autocorrelation Function sebelum differencing (lanjutan)*

30	0,122339	0,90
31	-0,016716	-0,12
32	0,025909	0,19
33	0,056859	0,42
34	-0,082586	-0,61
35	-0,038560	-0,28
36	0,094293	0,69
37	0,105855	0,78
38	-0,090125	-0,66
39	0,135822	1,00
40	0,133650	0,98
41	-0,049000	-0,36
42	-0,012427	-0,09
43	-0,035431	-0,26
44	-0,103604	-0,76
45	-0,042167	-0,31
46	-0,145240	-1,07
47	0,024973	0,18
48	-0,121932	-0,90
49	0,040330	0,30
50	-0,013010	-0,10

Lampiran Z2 *Output Minitab Partial Autocorrelation Function sesudah differencing*

```
MTB > PACF C2;
SUBC>    Lags 50.
```

Partial Autocorrelation Function: C2

Lag	PACF	T
1	-0,452767	-3,30
2	-0,454367	-3,31
3	-0,306622	-2,23
4	-0,230687	-1,68
5	-0,286227	-2,08
6	0,064027	0,47
7	-0,181250	-1,32
8	0,018463	0,13

Lampiran Z2 *Output Minitab Partial Autocorrelation Function*
 sesudah *differencing* (lanjutan)

9	-0,022209	-0,16
10	0,007756	0,06
11	-0,049588	-0,36
12	0,056797	0,41
13	-0,066077	-0,48
14	-0,071506	-0,52
15	0,104544	0,76
16	0,170271	1,24
17	0,034439	0,25
18	-0,110396	-0,80
19	-0,059076	-0,43
20	0,005704	0,04
21	-0,163661	-1,19
22	-0,136837	-1,00
23	-0,133310	-0,97
24	0,016024	0,12
25	-0,002714	-0,02
26	0,081867	0,60
27	0,057321	0,42
28	0,109946	0,80
29	-0,068142	-0,50
30	0,073483	0,53
31	0,033677	0,25
32	-0,009737	-0,07
33	0,100366	0,73
34	0,034160	0,25
35	-0,062323	-0,45
36	-0,073018	-0,53
37	0,140924	1,03
38	-0,118749	-0,86
39	-0,103156	-0,75
40	0,036384	0,26
41	-0,011308	-0,08
42	0,015839	0,12
43	0,005169	0,04
44	-0,068937	-0,50
45	0,026533	0,19
46	-0,094642	-0,69
47	0,075803	0,55
48	-0,046777	-0,34
49	0,011678	0,09
50	0,021560	0,16

Lampiran AA1 Syntax SAS Pengujian *Dickey Fuller* sebelum *diferencing*

```
data goldaab;  
input y;  
datalines;  
46  
34  
41  
49  
41  
.  
.  
.  
49  
62  
78  
50  
78  
;  
data goldaab;  
set goldaab;  
y1=lag1(y);  
yd=y-y1;  
run;  
proc reg data=goldaab;  
model yd=y1/noint;  
run;
```

Lampiran AA2 Syntax SAS Pengujian *Dickey Fuller* sesudah *differencing*

```
data goldab;
input y;
datalines;
*
-33
2
18
-16
.
.
.
-39
-2
-21
37
-47
;
data goldab;
set goldab;
y1=lag1(y);
yd=y-y1;
run;
proc reg data=goldab;
model yd=y1/noint;
run;
```


Lampiran AB1 *Output SAS Hasil Pengujian Dickey Fuller Sebelum Differencing*

Analysis of Variance					
Source	DF	Squares	Sum of Square	Mean F Value	Pr > F
Model	1	376.65704	376.65704	1.06	0.3084
Error	52	18513	356.02583		
Uncorrected Total	53	18890			
Root MSE	18.86865	R-Square	0.0199		
Dependent Mean	0.60377	Adj R-Sq	0.0011		
Coeff Var	3125.11960				
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
y1	1	-0.05048	0.04908	-1.03	0.3084

Lampiran AB2 *Output SAS Hasil Pengujian Dickey Fuller Sesudah Differencing*

Analysis of Variance						
Sum of Source	Mean	DF	Squares	Square	F Value	Pr > F
Model		1	39196	39196	135.77	<.0001
Error		51	14724	288.69849		
Uncorrected Total		52	53920			
Root MSE	16.99113	R-Square	0.7269			
Dependent Mean	0.76923	Adj R-Sq	0.7216			
Coeff Var	2208.84688					
Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
y1	1	-1.47134	0.12627	-11.65	<.0001	

Lampiran AC1 Syntax SAS Pengujian Model ARIMA (0,1,1)

```
data goldaab;
input y;
datalines;
46
34
41
49
41
.
.
.
49
62
78
50
78
;
proc arima data=goldaab;
identify var=y(1);
estimate
p=(0) q=(1)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran AC2 Syntax SAS Pengujian Model ARIMA (3,1,0)

```
data goldaab;
input y;
datalines;
46
34
41
49
41
.
.
.
49
62
78
50
78
;
proc arima data=goldaab;
identify var=y(1);
estimate
p=(1,2,3) q=(0)
noconstant method=cls
WHITENOISE=IGNOREMISS;
forecast out=ramalan lead=18;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran AD1 Output SAS Pengujian Model ARIMA (0,1,1)

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Approx Pr > t	Lag				
MA1,1	0.83346	0.07856	10.61	<.0001	1				
Variance Estimate			197.4432						
Std Error Estimate			14.05145						
AIC			431.5268						
SBC			433.4971						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.81	5	0.4390	-0.097	-0.157	0.076	0.082	0.070	0.172
12	8.73	11	0.6465	-0.147	0.133	0.058	-0.007	0.014	0.128
18	13.02	17	0.7350	-0.050	0.117	0.097	-0.078	-0.143	0.054
24	17.25	23	0.7966	0.097	0.034	-0.143	0.016	0.086	0.085
ests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.98848		Pr < W	0.8875				
Kolmogorov-Smirnov	D	0.064308		Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.026174		Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.187242		Pr > A-Sq	>0.2500				

Lampiran AD2 *Output* SAS Pengujian Model ARIMA (3,1,0)

Conditional Least Squares Estimation									
Parameter	Standard Estimate	Error	t Value	Pr > t	Lag				
AR1,1	-0.81766	0.13619	-6.00	<.0001	1				
AR1,2	-0.66971	0.15094	-4.44	<.0001	2				
AR1,3	-0.32030	0.13932	-2.30	0.0257	3				
Variance Estimate			213.0411						
Std Error Estimate			14.59593						
AIC			437.4779						
SBC			443.3888						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.24	3	0.0646	-0.078	-0.181	-0.123	-0.131	0.092	0.206
12	10.21	9	0.3334	-0.181	0.056	0.011	-0.031	-0.029	0.088
18	15.39	15	0.4236	-0.000	0.154	0.037	-0.144	-0.140	0.029
24	19.54	21	0.5503	0.077	0.044	-0.128	0.008	0.082	0.115
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.980995	Pr < W	0.5564					
Kolmogorov-Smirnov	D	0.068142	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.056641	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.369856	Pr > A-Sq	>0.2500					

Lampiran AE1 Penghitungan Manual rMSE ARIMA (0,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
63	79	16	256
63	51	-12	144
63	71	8	64
63	105	42	1.764
63	60	-3	9
63	58	-5	25
		<i>MSE</i>	377
		<i>rMSE</i>	19,416

Lampiran AE2 Penghitungan Manual sMAPE ARIMA (0,1,1)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
63	344	281	407	63	344
63	314	251	377	63	314
63	285	222	348	63	285
63	340	277	403	63	340
63	341	278	404	63	341
63	293	230	356	63	293
			<i>sMAPE</i>	1,3385	

Lampiran AE3 Penghitungan Manual rMSE ARIMA (3,1,0)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$(Z_t - \hat{Z}_t)$	$(Z_t - \hat{Z}_t)^2$
66	79	13	169
64	51	-13	169
57	71	14	196
61	105	44	1.936
63	60	-3	9

61	58	-3	9
		<i>MSE</i>	415
		<i>rMSE</i>	20,363

Lampiran AE4 Penghitungan Manual sMAPE ARIMA (3,1,0)

Ramalan <i>Out Sample</i>	Aktual <i>Out Sample</i>	$ Z_t - \hat{Z}_t $	$ Z_t + \hat{Z}_t $	$ Z_t + \hat{Z}_t /2$	$\frac{ Z_t - \hat{Z}_t }{1/2 Z_t + \hat{Z}_t }$
66	344	278	410	205	1,356098
64	314	250	378	189	1,322751
57	285	228	342	171	1,333333
61	340	279	401	200,5	1,391521
63	341	278	404	202	1,376238
61	293	232	354	177	1,310734
				<i>sMAPE</i>	1,348

Lampiran AF1 Nilai Peramalan Golongan Darah O

The SAS System		11:16 Wednesday, July 14, 2017 12				
Obs	y	FORECAST	STD	L95	U95	RESIDUAL
60	.	402.473	60.7274	283.449	521.496	.
61	.	402.819	62.9830	279.375	526.263	.
62	.	404.319	65.1606	276.607	532.032	.
63	.	406.050	67.2677	274.208	537.893	.
64	.	405.358	69.3107	269.511	541.204	.
65	.	401.319	71.2953	261.583	541.055	.
66	.	405.473	73.2261	261.953	548.994	.
67	.	404.059	76.5261	254.070	554.047	.
68	.	404.711	78.7617	250.341	559.081	.
69	.	405.537	80.9355	246.906	564.168	.
70	.	404.099	83.0525	241.319	566.879	.
71	.	404.525	85.1169	237.699	571.351	.
72	.	404.605	87.1323	233.828	575.381	.

Lampiran AF2 Nilai Peramalan Golongan Darah A

The SAS System			11:16 Wednesday, July 14, 2017 19			
Obs	y	FORECAST	STD	L95	U95	RESIDUAL
60	.	241.823	69.004	106.576	377.069	.
61	.	240.776	73.050	97.601	383.951	.
62	.	241.433	76.767	90.974	391.893	.
63	.	240.993	80.229	83.748	398.239	.
64	.	241.205	83.632	77.290	405.120	.
65	.	241.120	86.788	71.019	411.221	.
66	.	241.148	89.923	64.903	417.393	.
67	.	241.159	92.898	59.082	423.235	.
68	.	241.137	95.817	53.339	428.935	.
69	.	241.157	98.630	47.845	434.469	.
70	.	241.140	101.374	42.451	439.829	.
71	.	241.152	104.041	37.235	445.070	.
72	.	241.145	106.643	32.129	450.161	.

Lampiran AF3 Nilai Peramalan Golongan Darah B

The SAS System			11:16 Wednesday, July 14, 2017 33			
Obs	y	FORECAST	STD	L95	U95	RESIDUAL
60	.	297.006	47.2626	204.373	389.639	.
61	.	297.077	49.0562	200.928	393.225	.
62	.	297.059	50.7691	197.554	396.565	.
63	.	297.069	52.4294	194.309	399.829	.
64	.	297.067	54.0365	191.157	402.976	.
65	.	297.068	55.5976	188.099	406.037	.
66	.	297.068	57.1158	185.123	409.012	.
67	.	297.068	58.5947	182.224	411.911	.
68	.	297.068	60.0371	179.397	414.738	.
69	.	297.068	61.4457	176.636	417.499	.
70	.	297.068	62.8227	173.938	420.198	.
71	.	297.068	64.1702	171.297	422.839	.
72	.	297.068	65.4899	168.710	425.426	.

Lampiran AF4 Nilai Peramalan Golongan Darah AB

The SAS System			04:15 Wednesday, July 14, 2017 5			
Obs	y	FORECAST	STD	L95	U95	RESIDUAL
60	.	64.9151	14.9941	35.5271	94.3031	.
61	.	64.9151	15.1756	35.1714	94.6588	.
62	.	64.9151	15.3550	34.8198	95.0104	.
63	.	64.9151	15.5323	34.4724	95.3579	.
64	.	64.9151	15.7076	34.1288	95.7014	.
65	.	64.9151	15.8810	33.7890	96.0412	.
66	.	64.9151	16.0524	33.4529	96.3773	.
67	.	64.9151	16.2221	33.1203	96.7099	.
68	.	64.9151	16.3900	32.7912	97.0390	.
69	.	64.9151	16.5562	32.4655	97.3648	.
70	.	64.9151	16.7208	32.1429	97.6873	.
71	.	64.9151	16.8838	31.8235	98.0067	.
72	.	64.9151	17.0452	31.5072	98.3230	.

BIODATA PENULIS



Penulis bernama Dea Trishnanti dengan nama panggilan Dea, lahir di Kota Nganjuk tanggal 26 Desember 1995. Penulis adalah anak kedua dari dua bersaudara yang dilahirkan dari pasangan bapak Emon Sukasman dan ibu Mujiatun. Alamat domisili Nganjuk di jalan kapten tendean V nomor 4 Nganjuk. Pendidikan formal yang telah ditempuh penulis yaitu TK Khadijah 1 Nganjuk, SD Negeri Payaman II Nganjuk, SMP Negeri 1 Nganjuk dan SMA Negeri 2 Nganjuk. Setelah lulus dari SMA, penulis melanjutkan pendidikan ke diploma statistika ITS atau yang sekarang disebut Departemen Statistika Bisnis yang menjadi rumpun Fakultas Vokasi ITS. Masa pendidikan 3 tahun dengan NRP 1314030044 selain itu selama kuliah penulis pernah tergabung di organisasi JMMI periode 2014/2015 sebagai staff departemen pelayanan masyarakat, organisasi FORSIS periode 2015/2016 sebagai staff departemen syiar dan pada periode 2016/2017 sebagai pengurus harian. Selain aktif di organisasi, penulis juga aktif di beberapa kegiatan non-akademik yaitu panitia LKMM Pra-TD, LKMM TD, PKM 5 Bidang, PKM GT-AI dan event terbesar Pekan raya Statistika 2016 oleh HIMADATA ITS. Pada semester 4, penulis berkesempatan kerja praktek di PT. PAL Surabaya. Segala kritik dan saran akan diterima penulis dengan senang hati untuk keperluan diskusi. Kontak yang terhubung dengan penulis melalui email trishnantiidea@gmail.com atau melalui nomor telepon 083846752398 tersedia di aplikasi WhatsApp dan Line.